

**UNIVERSIDADE FEDERAL DO PARÁ
INSTITUTO DE TECNOLOGIA
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA**

TESE DE DOUTORADO

ARTHUR DA COSTA ALMEIDA

**METODOLOGIA INTEGRADA UTILIZANDO SENSORIAMENTO REMOTO E
REDES NEURAS ARTIFICIAIS NA QUANTIFICAÇÃO DO POTENCIAL DE
BIOMASSA FLORESTAL NA AMAZÔNIA**

TD 03 / 2008

**UFPA / ITEC / PPGEE
Campus Universitário do Guamá
Belém-Pará-Brasil
2008**

TESE

Dados Internacionais de Catalogação-na-Publicação (CIP) Biblioteca Central - UFPA

Almeida, Arthur da Costa;

Metodologia Integrada Utilizando Sensoriamento Remoto e Redes Neurais Artificiais na Quantificação do Potencial de Biomassa Florestal na Amazônia. / Arthur da Costa Almeida; orientadora, Brígida Ramati Pereira da Rocha. — 2008

Tese (Doutorado) - Universidade Federal do Pará, Instituto de Tecnologia, Programa de Pós-Graduação em Engenharia Elétrica, Belém, 2008.

1. Biomassa florestal - Amazônia. 2. Biocombustíveis - Amazônia.
3. Redes neurais (Computação). 4. Sistemas de informações geográficas. I. Título.

CDD - 22. ed. 553.09811

**UNIVERSIDADE FEDERAL DO PARÁ
INSTITUTO DE TECNOLOGIA
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA**

ARTHUR DA COSTA ALMEIDA

**METODOLOGIA INTEGRADA UTILIZANDO SENSORIAMENTO REMOTO E
REDES NEURAS ARTIFICIAIS NA QUANTIFICAÇÃO DO POTENCIAL DE
BIOMASSA FLORESTAL NA AMAZÔNIA**

**Tese submetida à Banca
Examinadora do Programa de
Pós-Graduação em Engenharia
Elétrica da UFPA para a
obtenção do Grau de Doutor em
Engenharia Elétrica.
Orientadora: Profa. Dra. Brígida
Ramati Pereira da Rocha.**

**UFPA / ITEC / PPGEE
Campus Universitário do Guamá
Belém-Pará-Brasil
2008**

UNIVERSIDADE FEDERAL DO PARÁ
INSTITUTO DE TECNOLOGIA
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA

METODOLOGIA INTEGRADA UTILIZANDO SENSORIAMENTO REMOTO E REDES
NEURAS ARTIFICIAIS NA QUANTIFICAÇÃO DO POTENCIAL DE BIOMASSA
FLORESTAL NA AMAZÔNIA

AUTOR: ARTHUR DA COSTA ALMEIDA

TESE DE DOUTORADO SUBMETIDA À AVALIAÇÃO DA BANCA EXAMINADORA
APROVADA PELO COLEGIADO DO PROGRAMA DE PÓS-GRADUAÇÃO EM
ENGENHARIA ELÉTRICA DA UNIVERSIDADE FEDERAL DO PARÁ E JULGADA
ADEQUADA PARA OBTENÇÃO DO GRAU DE DOUTOR EM ENGENHARIA
ELÉTRICA NA ÁREA DE SISTEMAS DE ENERGIA.

APROVADA EM 20 / 05 / 2008

BANCA EXAMINADORA:

Prof. Dra. BRÍGIDA RAMATI PEREIRA DA ROCHA
(ORIENTADORA – UFPA)

Prof. Dr. PAULO LUIZ CONTENTE DE BARROS
(MEMBRO – UFPA)

Prof. Dr. SUEO NUMAZAWA
(MEMBRO – UFPA)

Prof. Dr. ROBERTO CÉLIO LIMÃO DE OLIVEIRA
(MEMBRO – UFPA)

Prof. Dr. UBIRATAN HOLANDA BEZERRA
(MEMBRO – UFPA)

Prof. Dr. CARLOS TAVARES DA COSTA JUNIOR
(MEMBRO – UFPA)

Prof. Dr. ALEX VLADIMIR KRUSCHE
(MEMBRO – CENA/USP)

VISTO:

Prof. Dr. EVALDO GONÇALVES PELAES
(COORDENADOR DO PPGEE/ITEC/UFPA)

À minha mãe, Zuleide

Ela me ensinou a ler e a escrever

Ao meu pai, Arthur

Ele me ensinou a contar e a gostar dos números

AGRADECIMENTOS

Qualquer trabalho acadêmico, sempre é o resultado da contribuição de muitas pessoas que, de forma direta ou indireta, participaram de sua realização. Assim, registro a seguir os agradecimentos às pessoas e instituições que de alguma forma tiveram participação neste.

À Universidade Federal do Pará (UFPA), por ter me liberado por quatro anos da tarefa de ministrar aulas para que pudesse me dedicar de forma integral a esta pesquisa.

Às Centrais Elétricas do Norte do Brasil (ELETRONORTE) que através de seu programa de P&D do Ciclo 2004-2005 financiou parte desta pesquisa realizada no Reservatório de Tucuruí. Em especial ao Eng. Antonio Augusto Bechara Pardauil e ao Biólogo Tacachi Hatanaka.

Ao Instituto Nacional de Pesquisas Espaciais (INPE), que, através de seu site na internet, cedeu imagens de satélite e o software SPRING, que foram utilizados neste trabalho.

À Profa. Dra. Brígida Ramati Pereira da Rocha, da Faculdade de Engenharia Elétrica, do Instituto de Tecnologia da UFPA, orientadora deste trabalho, por ter compartilhado comigo tanto de seu tempo, de sua experiência, de sua amizade e de seus conhecimentos. Muito esclarecedoras foram as discussões sobre os rumos do trabalho, iluminadas por idéias que, mesmo à custa de mais trabalho a ser feito, sempre abriam novos caminhos, novas interpretações e, principalmente, modos diferentes de se olhar para a mesma realidade.

Ao Prof. Dr. Paulo Luiz Contente de Barros, da Universidade Federal Rural da Amazônia (UFRA), por ter compartilhado conosco sua grande experiência em engenharia florestal, pelo inventário florestal realizado em condições adversas na região amazônica, pela classificação das áreas antropizadas encontradas na região de estudo, pela amizade e pelo seu bom humor.

Ao Prof. Dr. Suelo Numazawa, vice-reitor da UFRA, pelos resultados de poder calorífico e densidade básica da biomassa coletada na área de estudo. Também pela amizade e seu modo sereno de encarar a vida.

Aos Professores Carlos Tavares da Costa Junior, Roberto Célio Limão de Oliveira e Ubiratan de Holanda Bezerra, da Faculdade de Engenharia Elétrica, do Instituto de Tecnologia da UFPA, e aos Professores Luis Augusto Barbosa Cortez e Kamal Ismail, da Universidade

Estadual de Campinas (UNICAMP), que participaram da Banca do Exame de Qualificação, por suas recomendações, que espero ter aproveitado no desenvolvimento do trabalho final. Ao Prof. Alex Krusche, do CENA-USP, por suas contribuições para este trabalho e por ter participado da Banca de Defesa da Tese.

Ao Eng. Carlos Simões Pereira, do Centro Operacional do Sistema de Proteção da Amazônia (SIPAM), por sua grande amizade e por sua ajuda no uso do programa ARCVIEW.

Aos Engenheiros José Humberto Araújo Monteiro e Luis Antonio Salim Lessa, membros de nosso grupo de pesquisas, pelas valiosas contribuições dadas a este trabalho e, principalmente, pela amizade cultivada durante todo esse tempo.

Aos colegas do doutorado, Celsa, Ivete, Tarcisio, e Hebe Morganne (a Dama do Lago), por sua amizade e apoio durante a elaboração deste trabalho.

Aos colegas da Faculdade de Matemática, do Campus de Castanhal, Edilberto, Geraldo e Valcir, que concordaram em trabalhar um pouco mais para que eu pudesse ser liberado.

À minha mãe, irmão e irmãs, pelo apoio e compreensão permanentes durante todas as fases deste e de todos os outros trabalhos que realizei.

A Luiza, ao Arthur, ao Allan. A esses, não preciso de motivos especiais. Basta a sua simples presença em minha vida.

CERTEZA E DÚVIDA

O pensador do passado
tinha muitas dúvidas
e uma grande certeza:
“Eu penso, logo existo.”

O pensador do futuro
terá muitas certezas
e uma grande dúvida:
“Eu existo nos neurônios
ou nos chips de silício?”

Arthur C. Almeida (1997)

RESUMO

Reconhecimento e classificação de padrões em imagens digitais é uma habilidade importante nos dias atuais, pois permite reconhecer e identificar objetos de interesse nessas imagens. Este trabalho propõe e implementa uma metodologia integrada de reconhecimento de padrões relacionados com biomassa na floresta amazônica, com o objetivo de extrair daí informações sobre potencial energético dessa biomassa para fins de utilização como combustível primário para produção de energia elétrica para eventual uso em comunidades isoladas da Amazônia. Para isso combina informações de inventário florestal obtidas em campo com classificação e reconhecimento de padrões de biomassa em imagens de satélite de média resolução (LANDSAT, CBERS). A técnica utilizada para isso vem da área de inteligência computacional: as redes neurais artificiais com arquitetura de Funções de Base Radial (RBF) e do tipo Mapa Auto-Organizável (SOM) de Kohonen. Os resultados são combinados em um Sistema de Informações Geográficas gerando um banco de dados para uso em planejamento energético com recursos renováveis, aplicáveis às áreas isoladas da Amazônia.

Palavras-chave: biomassa, energias renováveis, reconhecimento de padrões, redes neurais artificiais, sistemas de informações geográficas.

ABSTRACT

Pattern recognition and pattern classification in digital images is a very important skill, today. With them, it is possible to recognize and identify target objects in those images. This work proposes an integrated methodology for pattern recognition related to biomass in the Amazon tropical rainforest to extract information about bioenergetics potential for electric energy production for use with isolated Amazonian communities. To achieve this aim, information gathered about forest inventory was mixed with pattern classification and recognition in medium resolution satellite imagery such as those from LANDSAT and CBERS. The approach used in this work comes from the computational intelligence area, using artificial neural networks equipped with radial basis functions and Kohonen's self organizing maps. The results serve as input to a geographical information system application which creates and manages a geographical database for energetic planning with renewable energy resources applicable to isolated Amazonian communities.

Keywords: artificial neural networks, biomass, geographical information systems, pattern recognition, renewable energies.

SUMÁRIO

Capítulo 1	18
ENERGIA, MEIO AMBIENTE E PLANEJAMENTO ENERGÉTICO	18
1.1. Energia e Meio Ambiente	18
1.2. O Contexto Amazônico.	22
1.3. O Planejamento Energético e a Mudança de Paradigma.	24
1.4. Uso da Biomassa Como Combustível	26
1.5. O Projeto MEAPA.....	28
1.6. Trabalhos Relacionados.....	31
1.7. Organização do Trabalho.....	33
Capítulo 2	35
SENSORIAMENTO REMOTO E SIG	35
2.1 Sensoriamento Remoto com Imagens de Satélite.	35
2.1.1. <i>Sensoriamento Remoto da Vegetação.</i>	38
2.1.2. <i>Classificação de Imagens de Satélite.</i>	39
2.2 Sistemas de Informações Geográficas (SIG)	44
Capítulo 3	48
REDES NEURAIS ARTIFICIAIS	48
3.1 Redes Neurais Artificiais	48
3.2 Processos de Aprendizagem em uma Rede Neural Artificial	50
3.2.1 <i>Aprendizagem por correção de erro.</i>	50
3.2.2 <i>Aprendizado Competitivo.</i>	53
3.3 RNA e Processamento de Imagens.....	54
3.4 RNA e Aproximação de Funções.....	55
3.5 O Mapa auto-organizável de Kohonen ou Rede de Kohonen.....	57
3.5.1 <i>Aprendizado em uma rede de Kohonen</i>	59
3.6 Redes RBF (Funções de Base Radial).....	61
3.6.1 <i>Aprendizado em uma rede RBF.</i>	63
Capítulo 4	65
MATERIAL E MÉTODOS.....	65
4.1 Uma Metodologia Integrada	65
4.2 Metodologia para Inventário de Biomassa Florestal	69
4.2.1. <i>Crítérios de seleção dos modelos de regressão</i>	71
4.3 Metodologia para caracterização das áreas inventariadas das principais tipologias ocorrentes na área do entorno do reservatório da UHE-Tucuruí.....	75
4.3.1. <i>Metodologia para a classificação das áreas antropizadas</i>	75
4.3.2. <i>Definição das tipologias encontradas</i>	76
4.4 Metodologia para Tratamento da Imagem de Satélite.....	77
4.4.1. <i>Softwares utilizados.</i>	78
4.4.2. <i>Sensoriamento Remoto e processamento da imagem.</i>	78
4.4.3. <i>Redes Neurais Artificiais.</i>	79
4.4.4. <i>Sistemas de Informações Geográficas (SIG)</i>	79
Capítulo 5	80
INVENTÁRIO FLORESTAL DA ÁREA DE ESTUDO.....	80
5.1 Caracterização da Área de Estudo.....	80
5.1.1 <i>Coleta de Dados Para Obtenção da Estimativa do Volume.</i>	83
5.1.2 <i>Coleta de dados Para Densidade Básica e Poder Calorífico</i>	87

Capítulo 6	88
RESULTADOS E DISCUSSÃO.....	88
6.1 Resultados.....	88
6.1.1 <i>Volume de Biomassa</i>	88
6.1.2 <i>Potencial Energético</i>	88
6.2 Discussão.	90
6.2.1 <i>Discussão global dos resultados.</i>	90
6.2.2 <i>Variação dos resultados em função da tipologia florística.</i>	94
6.2.3 <i>Desempenho da rede RBF para aproximação de funções</i>	96
6.2.4 <i>Desempenho da rede de Kohonen para classificação de imagem.</i>	101
6.2.5 <i>Sistema de Informações Geográficas e Banco de Dados Espaciais.</i>	104
6.2.6 <i>Restrições</i>	106
Capítulo 7	108
CONCLUSÃO.....	108
REFERÊNCIAS	110
APÊNDICE A	115
APÊNDICE B.....	118
APÊNDICE C.....	127

LISTA DE FIGURAS

Figura 1 - Mapa da Amazônia Legal (ADA, 2008).....	22
Figura 2 – Resultado do MEAPA mostrando potencial de biomassa no Marajó.....	29
Figura 3 – Resultado do MEAPA mostrando porcentual de dias com insolação no Marajó...	30
Figura 4 - Níveis de Intensidade nas bandas 1, 2 e 3 de uma imagem do LANDSAT da região do entorno do Reservatório de Tucuruí.....	37
Figura 5 - Imagem do LANDSAT do entorno de Belém, destacando-se diferentes tipos de cobertura do solo (INPE, 2007).....	42
Figura 6 - Esquema da aprendizagem Widrow-Hoff.....	51
Figura 7 - Esquema de uma rede de Kohonen (HAYKIN, 2001).	58
Figura 8 - Esquema de uma Rede Competitiva. Adaptado de Demuth e Beale (2002).....	59
Figura 9 - Esquema de uma Rede RBF. Adaptado de Demuth e Beale (2002)	62
Figura 10 – Esquema de extração dos Dados da Imagem do LANDSAT com o Programa SPRING.....	65
Figura 11 – Esquema de treinamento da Rede RBF.....	66
Figura 12 – Esquema de simulação de Rede RBF.....	67
Figura 13 – Classificação de Imagem com Rede de Kohonen.....	67
Figura 14 – Esquema da entrada na aplicação SIG	68
Figura 15 – Esquema da entrada de dados na Aplicação MEAPA	69
Figura 16 - Esquema da coleta de dados para o cálculo do volume real, pela metodologia de Smalian (CAMPOS et al, 1985).	71
Figura 17 – Fotografia da bomba calorimétrica usada para determinação do poder calorífico.	74
Figura 18 – Esquema do método de aquisição das imagens das áreas antropizadas.....	76
Figura 19 - Arquitetura da rede RBF	79
Figura 20 - Área de estudo: Entorno do Reservatório de Tucuruí. Área situada entre os paralelos 3° 42’S e 4° 56’S e os meridianos 49° 20’W e 49° 58’W	81
Figura 21 – Fotografia do deslocamento da equipe no interior do lago.	84
Figura 22 – Fotografia mostrando deslocamento da equipe no interior do lago.....	84
Figura 23 - Fotografia da equipe de coleta de dados de campo para cubagem do volume real do fuste.	85
Figura 24 – Fotografia mostrando derruba das árvores - Coleta de dados de campo para cubagem do volume real do fuste.	85
Figura 25 – Fotografia da equipe fazendo coleta de dados de campo para cubagem do volume real do fuste.	86
Figura 26 – Fotografia da equipe fazendo registro dos dados de campo para cubagem do volume real de copa.	86
Figura 27 - Volume de biomassa em uma região do reservatório de Tucuruí.....	89
Figura 28 – Potencial energético em uma região do reservatório de Tucuruí.....	89
Figura 29 – Comparativo Entre Dados Reais e Estimados	91
Figura 30 - Comparativo entre dados reais e estimados	92
Figura 31 - Diagrama de dispersão dos dados.....	93
Figura 32 – Histograma dos dados reais (A) e estimados (B).....	94
Figura 33 - Variação dos índices por tipologia florística.....	96
Figura 34 - Superfície gaussiana usada na rede RBF	97
Figura 35 - Situação final dos pesos da camada de entrada da rede RBF.....	100
Figura 36 - Situação final dos pesos da camada linear da rede RBF.....	101
Figura 37 - Imagem original (A) e classificada (B).....	103
Figura 38 - Histograma da imagem original (A) e classificada (B)	104

Figura 39 – Mapa A1 (1 de 8) mostrando volume estimado de biomassa.....	119
Figura 40 - Mapa A2 (2 de 8) mostrando volume estimado de biomassa	120
Figura 41 - Mapa A3 (3 de 8) mostrando volume estimado de biomassa	121
Figura 42 - Mapa A4 (4 de 8) mostrando volume estimado de biomassa	122
Figura 43 - Mapa B1 (5 de 8) mostrando volume estimado de biomassa.....	123
Figura 44 - Mapa B2 (6 de 8) mostrando volume estimado de biomassa.....	124
Figura 45 - Mapa B3 (7 de 8) mostrando volume estimado de biomassa.....	125
Figura 46 - Mapa B4 (8 de 8) mostrando volume estimado de biomassa.....	126
Figura 47 - Mapa A1 (1 de 8) mostrando volume estimado de potencial energético.....	128
Figura 48 - Mapa A2 (2 de 8) mostrando volume estimado de potencial energético.....	129
Figura 49 - Mapa A3 (3 de 8) mostrando volume estimado de potencial energético.....	130
Figura 50 - Mapa A4 (4 de 8) mostrando volume estimado de potencial energético.....	131
Figura 51 - Mapa B1 (5 de 8) mostrando volume estimado de potencial energético.....	132
Figura 52 - Mapa B2 (6 de 8) mostrando volume estimado de potencial energético.....	133
Figura 53 - Mapa B3 (7 de 8) mostrando volume estimado de potencial energético.....	134
Figura 54 - Mapa B4 (8 de 8) mostrando volume estimado de potencial energético.....	135

LISTA DE TABELAS

Tabela 1 – Características Técnicas do Satélite LANDSAT (NASA, 2008).....	36
Tabela 2 - Modelos pré-selecionados para serem ajustados para determinação de equações de volume para a floresta.	72
Tabela 3 - Dados de inventário coletado no campo.....	87
Tabela 4 - Índices estatísticos dos inventários por tipologia florística	95
Tabela 5 - Planilha com dados de inventário florestal usado para entrada na rede neural	115

LISTA DE SIGLAS

ABNT	Associação Brasileira de Normas Técnicas
ARCVIEW	Programa de SIG
ASTM	American Society for Testing and Materials
CBERS	Satélite Sino-Brasileiro de Recursos Terrestres
ELETRONORTE	Centrais Elétricas do Norte do Brasil
IBGE	Instituto Brasileiro de Geografia e Estatística
INESC	Instituto de Engenharia de Sistemas e Computadores
INPE	Instituto Nacional de Pesquisas Espaciais
IPCC	Painel Inter-governamental sobre Mudanças Climáticas
kWh	kiloWatt-hora
LANDSAT	Programa de Satélites da Nasa para observar recursos terrestres
MATLAB	Matrix Laboratory (Software de matemática aplicada)
MDL	Mecanismo de Desenvolvimento Limpo
MEAPA	Mapeamento de Energias Alternativas no Estado do Pará
MME	Ministério de Minas e Energia
NDVI	Normalized Difference Vegetation Index
PCI	Poder Calorífico Inferior
PCS	Poder Calorífico Superior
PIR	Planejamento Integrado de Recursos
RBF	Radial Basis Functions (Funções de Base Radial)
RMS	Root Mean Square
RNA	Redes Neurais Artificiais
SECTAM	Secretaria Executiva de Ciência, Tecnologia e Meio Ambiente
SIG	Sistemas de Informações Geográficas
SIPAM	Sistema de Proteção da Amazônia
SOLARGIS	Aplicação em SIG para planejamento energético com energia eólica e solar
SOM	Self Organizing Map
SPRING	Programa de SIG fornecido pelo INPE
TIN	Triangular Irregular Network
UFPA	Universidade Federal do Pará
UFRA	Universidade Federal Rural da Amazônia

UNICAMP	Universidade Estadual de Campinas
USAID	United States Agency for International Development
USGS	United States Geological Survey
UTM	Universal Traverse Mercator

Capítulo 1

ENERGIA, MEIO AMBIENTE E PLANEJAMENTO ENERGÉTICO

1.1. Energia e Meio Ambiente

Um suprimento adequado e eficiente de energia é condição necessária e essencial ao desenvolvimento de qualquer comunidade humana.

O antropólogo Leslie White afirma (BARRETT, 1989) que "as sociedades podem ser colocadas em uma escala, da mais simples a mais complexa, e que as diferenças entre elas podem ser medidas pela sua capacidade de produção de energia".

Conforme diz Oliveira (1998):

"A confirmação empírica dessa percepção veio através dos estudos que correlacionaram séries históricas e séries cruzadas de crescimento do PIB per capita com o consumo de energia per capita. Desde então, passou-se a visualizar o crescimento do consumo de energia como fator motriz do crescimento econômico. Não é surpreendente, pois, que no pós-guerra, a política energética brasileira tenha se alinhado com o que ocorria no resto do mundo, adotando como principal orientação disponibilizar energia barata para os agentes econômicos".

Exemplo dessa percepção e dessa atitude política foi a construção, no Estado do Pará, da Hidrelétrica de Tucuruí.

Por isso mesmo, nas últimas décadas, tem-se observado uma preocupação cada vez maior dos governos com a chamada "questão energética", tanto pela parte da garantia de seu suprimento, como pelos problemas ecológicos e ambientais que a energia, em todas as fases de produção e utilização, vem causando ao ambiente planetário (PARKS, 2004).

É sabido que a maior parte dos países desenvolvidos obtém a energia de que necessitam a partir da transformação de combustíveis fósseis, notadamente o petróleo e o carvão mineral. Segundo (GOSWAMI e KREITH, 2007), 80% da demanda total de combustível primário é formada por combustível fóssil, sendo 35,5% petróleo, 23% carvão mineral e 21,2% de gás natural. A biomassa, apesar de representar somente 11% dessa demanda, ainda é usada de forma tradicional e ineficiente em sua maior parte (GOSWAMI e KREITH, 2007).

O combustível fóssil, ao ser utilizado em grande escala como fonte primária de energia, libera grandes quantidades de CO₂, metano e partículas de enxofre. Esses gases, presentes na atmosfera terrestre em pequenas quantidades, vêm tendo sua quantidade aumentada em proporção significativa, a partir da Revolução Industrial, por conta dos novos processos de produção e de transformação de energia. Por outro lado, tem havido um aumento do desmatamento em algumas regiões do globo, por exemplo, nas florestas da Amazônia, mesmo sabendo-se que a vegetação é responsável por uma grande absorção de carbono da atmosfera, por meio do processo de fotossíntese. Por conta disso, alguns problemas têm sido detectados em relação ao ambiente planetário.

Alguns desses principais problemas são relacionados por (REIS, 2001): poluição do ar urbano, chuva ácida, efeito estufa e as mudanças climáticas, desflorestamento e desertificação, degradação marinha e costeira e alagamentos.

Desses, o mais grave, urgente e abrangente é o efeito estufa e as mudanças climáticas dele advindas.

O efeito estufa é provocado pela presença, na atmosfera terrestre de gases, como o dióxido de carbono (CO₂), ozônio (O₃), metano (CH₄) e óxido nitroso (N₂O), juntamente com o vapor de água (H₂O), chamados "gases do efeito estufa", que permitem a entrada de radiação solar na faixa visível do espectro, mas impedem o seu retorno na faixa infravermelha do mesmo, oriunda do aquecimento da superfície da Terra e dos oceanos. O resultado líquido disso é um aquecimento adicional da superfície terrestre, causado pela atmosfera.

O efeito estufa é um processo natural que permite uma temperatura mais amena na superfície terrestre e é um dos fatores que favorecem a vida na Terra. Entretanto, desde a Revolução Industrial, tem sido observado um aumento da presença dos gases do efeito estufa na atmosfera terrestre, ocasionando, segundo teorias recentes, um aquecimento global do planeta, traduzido por um aumento gradual na temperatura média da Terra (PARKS, 2004).

Medições históricas concluíram que a temperatura média global da Terra já sofreu um aumento de 0,5 graus centígrado nos últimos cem anos e que essa média positiva está em crescimento. A hipótese de variação sazonal é considerada mínima, devendo esse efeito ser atribuído ao crescimento exponencial de emissão de gases de efeito estufa por atividades antropogênicas. Em caso de dúvida, deve-se levar em conta a recomendação da "Carta da Terra" (UNESCO, 2000):

"Prevenir o dano ao ambiente como o melhor método de proteção ambiental e, quando o conhecimento for limitado, tomar o caminho da prudência".

Uma boa razão para se tomar o caminho da prudência nesse assunto é considerar que o clima da Terra é um exemplo típico de sistema dinâmico caótico, estudado por Lorenz (1996), já na década de 60. Ora, a característica principal de um sistema dinâmico caótico é sua extrema sensibilidade a pequenas variações em seus parâmetros ou variáveis (DEVANEY, 1996). Segundo Parks (2004), a contribuição dos gases de efeito estufa, oriunda de causas antropogênicas, é da ordem de 2%. À luz da teoria dos sistemas dinâmicos caóticos isso é mais do que suficiente para perturbar de forma significativa a médio e longo prazo um sistema como o clima da Terra.

As perturbações possíveis de serem causadas por um aumento do efeito estufa e o conseqüente aquecimento global do planeta podem ser distribuídas da seguinte forma:

- (a) *recursos de água*: a qualidade e quantidade de água potável, disponibilidade de água para irrigação e uso industrial e até geração de eletricidade, pode ser afetada. Com o aumento de temperatura, poderá haver um aumento de evaporação da água e, portanto, chuvas mais freqüentes e copiosas, com alagamentos e inundações.
- (b) *elevação do nível dos oceanos*: com o aumento de água nos mares, provocado pelo degelo das calotas polares, causado pelo aquecimento da Terra, certas cidades litorâneas, poderão ser inundadas, ou se tornarem impróprias para habitação humana.
- (c) *aumento de doenças* principalmente nas regiões tropicais, pois um aumento de temperatura e umidade, favorece populações de insetos nocivos à saúde humana e à agricultura.
- (d) *escassez de alimentos*: a agricultura pode ser bastante prejudicada com uma mudança significativa no clima do planeta.

Estima-se que, no Brasil, o maior impacto será na alteração do regime de chuvas e da temperatura, com conseqüências diretas sobre a agricultura e a biodiversidade. A ocorrência de desastres naturais e de quebras de safra também poderá tornar-se mais freqüente e intensa. O risco de enxurradas e deslizamentos de terra tenderá a aumentar.

Os mapas divulgados pelo IPCC (IPCC, 2007) sugerem que uma área que abrange o norte da Bahia, todo o sertão nordestino, boa parte dos estados do Pará, do Amazonas e de Mato Grosso pode ter um acréscimo de até 1,5°C na temperatura média entre 2020 e 2029. Esse mesmo cenário aponta que a temperatura da região pode sofrer um aumento de até 3,5 °C entre 2090 e 2099. Em outros dois cenários, o clima da América do Sul varia de forma homogênea entre 2020 e 2029, com uma alta de 1°C. Entre 2090 e 2099, no entanto, o aquecimento afetaria com maior intensidade o interior do continente.

A Convenção-Quadro das Nações Unidas sobre a Mudança do Clima, assinada na Conferência Rio-92 por 175 países mais a União Européia, ratifica a preocupação com o aquecimento global. Os riscos são grandes demais para serem ignorados, e os governos dos países estão negociando limitação e cortes na emissão de gases de efeito estufa para a atmosfera.

O Protocolo de Quioto, de 1997, procurando atingir o objetivo final da Convenção, no sentido de possibilitar alcançar a estabilização das concentrações de gases de efeito estufa na atmosfera num nível que não interfira perigosamente no sistema climático, estabelece metas e prazos para controlar num primeiro esforço quatro gases: dióxido de carbono, metano, óxido nítrico e hexafluoreto de enxofre (SF₆), acompanhados por duas famílias de gases, hidrofluorcarbonos (HFCs) e perfluorcarbonos (PFCs) (QUIOTO, 2008).

Entre os grandes responsáveis pelo aumento da emissão de gases de efeito estufa está o setor energético nas áreas industrial, de transportes e de geração de energia elétrica.

Portanto, a utilização de alguns tipos de fontes renováveis de energia surge como uma alternativa viável para a redução de emissão de gases de efeito estufa na atmosfera, sem prejudicar a oferta de energia necessária ao desenvolvimento e ao crescimento econômico e social.

Entre as medidas do Governo Brasileiro, relacionadas ao uso de fontes renováveis de energia, especialmente na Amazônia, está a assinatura do Memorandum de Entendimento com o USAID (United States Agency for International Development) (USAID, 2008) em 2003, considerando que: "A falta de energia elétrica é um dos maiores entraves ao desenvolvimento de comunidades isoladas, principalmente no Norte e no Nordeste do Brasil. O uso de tecnologias de energia renovável é uma alternativa para estimular o desenvolvimento econômico e social dessas regiões, pois podem ser utilizadas em atividades como irrigação, secagem de frutas, refrigeração de vacinas e bombeamento de água. Isso possibilita aos beneficiários aumento de renda e capacidade de pagamento por serviços de energia.

Atualmente há cerca de 12 milhões de pessoas sem acesso a energia elétrica no Brasil, número superior à população da Bolívia. Do total, dez milhões moram em áreas rurais. Especialistas em desenvolvimento afirmam que a simples extensão de rede elétrica, ou instalação de geradores a diesel, não resolve o problema, sendo necessário que o acesso à energia possibilite às famílias beneficiadas, ampliação das atividades econômicas e aumento na capacidade de geração de renda." (MME, 2004).

1.2. O Contexto Amazônico.

Segundo o Balanço Energético Nacional (MME, 2007), com base em dados de 2006, a Região Norte produz 12,9% da energia hidráulica do Brasil e o Estado do Pará é responsável por 10,14% da produção nacional dessa energia e 78,08% da produzida na Região Norte, sendo um exportador de energia elétrica para outras regiões do país. Mesmo assim, grande parte de seu território e de sua população, notadamente aquela que vive na zona rural ao norte do Rio Amazonas, não tem acesso ao serviço público de energia elétrica, estando condenada, assim, à pobreza e a uma má qualidade de vida, de acordo com os padrões atuais de desenvolvimento e civilização. Só no Pará, segundo o IBGE (2007), de seus 7 milhões de habitantes, 1,5 milhões não dispõem de acesso a um serviço público de energia elétrica.

A região amazônica, cujo mapa é mostrado na Figura 1, está habitada por aproximadamente 20 milhões de brasileiros. Tem 11 mil quilômetros de fronteira e 56% do território nacional, e é a região que apresenta ao país o maior desafio em sua indagação para um modelo de desenvolvimento sustentável. A região apresenta condição ambiental bastante diversificada, incluindo floresta e campos, savanas e plantas aquáticas. Além de sua biodiversidade, a bacia hidrográfica contém um quinto da água doce do mundo.

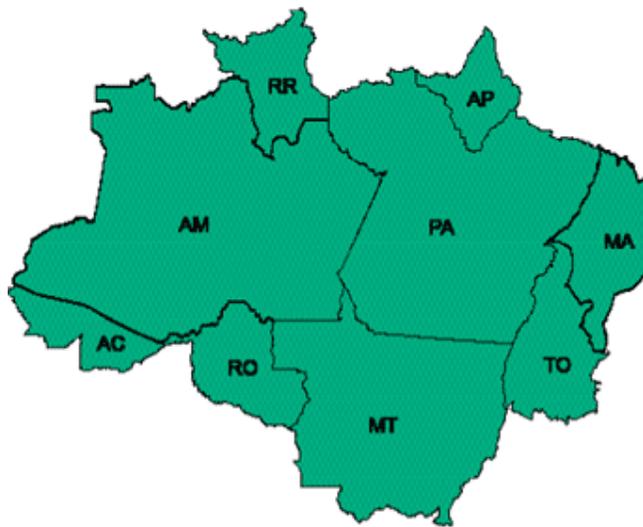


Figura 1 - Mapa da Amazônia Legal (ADA, 2008).

Nela, predomina o clima equatorial úmido, gerando altas taxas de precipitação pluviométrica (cerca de 2.500 mm anuais). A temperatura é estável, em torno de 25°C. Em uma pequena porção setentrional da região (Roraima), registra-se o clima equatorial semi-úmido, quente, mas menos chuvoso. O fenômeno deve-se ao relevo acidentado (o planalto

residual norte-amazônico), e às correntes de ar que levam as massas equatoriais para o sul, entre os meses de setembro a novembro. No sudoeste da região (Mato Grosso e parte do Amazonas), está presente o clima tropical, que recebe influências do equatorial úmido (quente) e de massas polares vindas do sul (frio).

A vegetação é fortemente influenciada pelo clima equatorial e pela hidrografia: juntos propiciaram a formação da floresta Amazônica, a mais exuberante e diversificada floresta no planeta, e que ocupa cerca de 40% do território brasileiro (3,5 milhões de km²).

No que se refere à infra-estrutura básica, a questão energética tem papel fundamental, pois tem sido um desafio à administração governamental, porque o fornecimento de energia elétrica às populações de algumas regiões da Amazônia, dispersas e isoladas das áreas que já possuem fornecimento de energia elétrica, é inadequado devido ao pequeno consumo de energia nestas comunidades e suas localizações serem distantes das redes de distribuição existentes. Com exceção das sedes dos municípios, a maioria das áreas rurais da Amazônia não dispõe de serviço público de energia elétrica. Além disso, em muitos municípios, como por exemplo, os da Região do Marajó, a energia elétrica é fornecida por geradores a diesel, consumindo combustível fóssil e com atendimento apenas das sedes dos municípios e algumas poucas localidades, deixando a zona rural quase completamente sem atendimento.

Algumas características peculiares da região amazônica, relacionadas a um possível suprimento convencional de energia elétrica podem ser mencionadas:

- (a) *grandes rios*: rios com largura que podem variar de centenas de metros a alguns quilômetros, como por exemplo entre Belém e a Ilha de Combu (1,3 km) e entre a Ilha de Mosqueiro e o Arquipélago do Marajó, próximo à Foz do Amazonas (30 km).
- (b) *baixa densidade populacional* em algumas regiões chegando a menos de 1 hab/km², o que torna oneroso o investimento em linhas de transmissão e sistemas de distribuição.
- (c) *abundância de chuvas*: atingindo uma média anual entre 2000 e 2500 mm, com concentração nos meses de janeiro a abril, responsáveis por cerca de metade das chuvas anuais.
- (d) *grande dispersão geográfica dos consumidores*;
- (e) *elevados investimentos necessários à implementação de redes de distribuição*;
- (f) *longas extensões de linhas para o atendimento de cargas leves e dispersas*;
- (g) *elevados custos de operação e manutenção dos sistemas elétricos*;
- (h) *pouca atratividade para os investidores, em razão dos baixos níveis de rentabilidade dos investimentos*.

Isso mostra que as características da questão energética na região amazônica poderiam ser interpretadas como vantagem para a introdução de fontes renováveis de energia, pois entre as vantagens de algumas destas fontes está a possibilidade de uso em pequena escala, não necessitando de grandes redes de distribuição nem de grandes investimentos, o que resolveria o problema de abastecimento de pequenas propriedades e das comunidades isoladas.

Mas o que se vê na Amazônia é um modelo energético completamente diferente. Segundo Rocha e Silva (2000):

"... modelo de oferta de energia acompanhou o modelo de distribuição de renda, ampliando a geração centralizada de energia, beneficiando o mercado "capital", que se encontra nas cidades mais importantes da Amazônia e nos projetos eletro-intensivos (23,1% do consumo de energia do país). Esse modelo gerou também um esquecimento das populações dispersas na área amazônica, com densidades populacionais às vezes menores que 1hab/km², mas que no total atingem cerca de 20 milhões de habitantes sem oferta adequada de energia."

As dificuldades de atendimento a esse mercado rural, das comunidades isoladas da Amazônia, são intrínsecas à sua própria dispersão territorial, o que provoca altos investimentos de instalação e baixo consumo, proporcionando assim um lento retorno do investimento.

A instalação de redes, como tem sido financiada em condições favoráveis pelos programas Luz no Campo e, atualmente, Luz Para Todos, nunca será, especialmente na Amazônia, uma solução completa e nem sempre será a opção de menor custo para a eletrificação das comunidades isoladas da Amazônia. Como complemento, o uso de geração descentralizada, local, com fontes renováveis de energia, parece ser a solução mais viável para esse problema.

1.3. O Planejamento Energético e a Mudança de Paradigma.

A atividade tradicional de planejamento energético consistia, basicamente, em aumentar a oferta de energia, com eficiência, confiabilidade e o menor custo possível. Entretanto, hoje, reconhecido o caráter agressivo ao meio-ambiente de quase todas as etapas envolvidas no processo de fornecimento de energia, com o aumento da consciência ecológica, tais parâmetros se mostraram insuficientes para um planejamento energético ecologicamente correto. Há que se levar em conta, de forma séria e abrangente, o custo ambiental do fornecimento de energia, o impacto social e humano que ele pode causar. E esta nova

perspectiva, muda de forma completa o ato de planejar, pois envolve áreas diversas como modelagem matemática de ambientes, crescimento de populações, aspectos econômicos e sociais das comunidades envolvidas.

Também, até há pouco tempo, o cenário de geração de energia elétrica era inteiramente dominado pelas grandes centrais. Parecia que não havia outro caminho para produção de energia. Por várias décadas, as pequenas usinas desapareceram do cenário. Isto ocorreu em escala mundial, baseado no argumento de que a eficiência elétrica só podia ser obtida a partir da concentração em grandes usinas geradoras e, portanto, elas seriam a melhor solução, em termos de economia e eficiência. Como consequência dessa política, as pequenas comunidades rurais se viram abandonadas, pois estavam isoladas das grandes linhas de transmissão e sistemas de distribuição de energia elétrica. Só recentemente, com o crescimento populacional e desenvolvimento de outras nações, constatou-se, no Brasil, que a produção distribuída de energia era uma solução necessária para a universalização do atendimento de energia elétrica a essas populações crescentes e geograficamente dispersas (SIMÕES e FARRETT, 2006).

Além disso, colocam-se questões como o uso eficiente, pelo usuário final, da energia disponível, conforme (JANNUZZI, 1997):

"Isto requer a integração de um vasto leque de opções tecnológicas, incluindo tecnologias para o uso eficiente da energia, e controle da carga pelo "lado da demanda", assim como o uso de fontes descentralizadas, na cesta de recursos disponíveis."

Segundo o mesmo autor, estes são os passos a serem seguidos por um planejamento integrado de recursos (PIR):

1. Coleta de dados confiáveis sobre os padrões de uso final da energia e alternativas tecnológicas para melhorar o uso eficiente da energia, ou os padrões de carga.
2. Definição e projeção dos futuros cenários de uso de energia.
3. Cálculo dos custos e impactos das alternativas "pelo lado da demanda",
4. Comparação dos custos de implantação com os custos dos impactos sociais e ambientais entre as opções tradicionais e alternativas.
5. Definição de um plano de suprimento e demanda que atenda aos critérios de custo mínimo, tanto do ponto de vista econômico como social e ambiental.
6. Implementação da estratégia de custo mínimo".

1.4. Uso da Biomassa Como Combustível

De acordo com Goswami e Kreith (2007), os combustíveis oriundos da biomassa derivam das plantas verdes que capturam energia solar e a armazenam sob a forma de energia química, através da fotossíntese, que é um processo químico de redução do dióxido de carbono presente na atmosfera. Nesse aspecto, as folhas das plantas atuam como coletores biológicos de energia solar e os seus talos e caules como baterias armazenando energia química, sob a forma de complexos compostos de carbono. De acordo ainda com os mesmos autores, a eficiência da conversão da energia solar é baixa, da ordem de 0,5% nos climas temperados e de até 1,5% nas florestas tropicais. Entretanto, a soma total de energia de biomassa armazenada em escala planetária é estimada em 10 vezes o consumo mundial de energia em um ano.

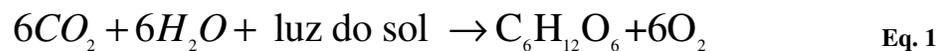
A importância da vegetação no balanço energético do planeta ainda está longe de ser completamente elucidada. Sabe-se, entretanto que o processo de fotossíntese é o meio que as plantas possuem para capturar e armazenar energia solar.

De acordo com (JENSEN, 2000) mais de 90% da energia usada em nossa sociedade tecnológica atual para geração de eletricidade, transporte, aquecimento, refrigeração e uso industrial, vem do petróleo e do carvão mineral. Mas essa energia contida no petróleo e no carvão veio, por sua vez, através do processo de fotossíntese de plantas que existiram há milhões de anos atrás e foi transformada nesses combustíveis fósseis por forças e processos que atuam em escala de tempo geológico (milhões de anos).

Nesse cenário, devemos encarar a fotossíntese como o principal processo de obtenção de energia que possibilita atualmente a existência e a sobrevivência de nossa civilização, mesmo que de forma indireta (JENSEN, 2000).

Em essência, o processo de fotossíntese consiste em capturar a energia solar e transformá-la por meio de processos físicos e químicos em moléculas de açúcar e oxigênio, a partir da água e do dióxido de carbono (CO₂), liberando oxigênio (O₂).

Assim, do ponto de vista da química, o processo de fotossíntese é descrito pela Equação 1:



A fotossíntese é um processo que ocorre nas folhas e nas partes verdes das plantas em presença da luz do sol. A energia luminosa é armazenada na forma de moléculas simples de açúcar, glicose, obtidas a partir do dióxido de carbono presente no ar e de moléculas de água

absorvidas pelas raízes e folhas das plantas. Quando o carbono e a água se combinam e formam a molécula de açúcar $C_6H_{12}O_6$ nos cloroplastos, pequenos corpos contendo uma substância verde, a clorofila, o oxigênio (O_2) é liberado (BECK, LIEN, SIMPSON, 1991).

A energia da biomassa pode ser convertida em outras formas de energia tais como combustíveis líquidos ou gasosos e eletricidade.

Nas últimas décadas, o uso de biomassa para produção de biocombustíveis, em suas várias formas, seja como combustível primário na geração de eletricidade, calor ou no transporte, tem se tornado um foco de renovado interesse em escala mundial. No Brasil, os programas do álcool combustível e do biodiesel são os mais conhecidos. Entretanto, experiências locais estão sendo feitas para o uso de resíduos de agricultura e de floresta como combustível para a geração de eletricidade, por meio de gaseificadores funcionando à pressão ambiente (ALMEIDA, MONTEIRO e ROCHA, 2007) e o aproveitamento de óleos vegetais *in natura* em motores de combustão interna.

Os sistemas atuais que usam biomassa em caldeiras de baixa pressão operam em uma faixa de eficiência de 10%, podendo, com algumas modificações, atingirem 20% de eficiência. Entretanto, tecnologias mais avançadas convertem biomassa sólida em gás de baixo poder calorífico, pelo processo de gaseificação, que combinadas com o uso de turbinas a gás, podem atingir uma eficiência de até 40% (GOLDEMBERG e VILLANUEVA, 2003).

Essa tecnologia pode atingir eficiência superior a 40%, usando gaseificação sob alta pressão. Se isso for conseguido, as implicações globais podem ser significativas, com a biomassa contribuindo na produção de eletricidade numa escala similar à energia nuclear e hidroelétrica em meados do século XXI, uma vez que ela poderá ser utilizada em todo o mundo e, particularmente, na Amazônia (GOLDEMBERG e VILLANUEVA, 2003).

A crescente disponibilidade de biomassa, combinada com o desenvolvimento de tecnologias que a usam de forma mais eficiente, promete tornar a biomassa uma opção cada vez mais atraente como combustível primário.

O poder calorífico médio da biomassa é da ordem de 20000 kJ/kg, com uma variação de mais ou menos 15%. Em um gaseificador, obtém-se em média 1 kWh para cada 1 a 1,5 kg de biomassa. (QUAAK, KNOEF, STASSEN, 1999).

Para a produção de eletricidade, a biomassa pode ser usada com as seguintes tecnologias:

- Caldeira a vapor.
- Turbina a vapor com motor de ciclo Rankine

- Motor de combustão interna, que pode ser do ciclo Otto, com ignição por centelha ou a diesel, com ignição por compressão.
- Turbina a gás, com motor do ciclo Brayton
- Motor Stirling.

No caso de caldeira, a biomassa é usada *in natura*, enquanto que para os motores de combustão interna ou turbinas, ela deve antes sofrer um processamento que a transforme em combustível líquido (álcool ou biodiesel) ou gasoso, como no caso do gaseificador e biodigestores.

A biomassa, em contraste com os combustíveis fósseis, pode dar um impacto positivo ao meio ambiente, pois em um cenário de desenvolvimento sustentável, o dióxido de carbono (CO₂) emitido durante a sua combustão, será absorvido durante o crescimento da nova biomassa, contribuindo assim para mitigar a emissão de gases de efeito estufa na atmosfera.

Além disso, a biomassa pode ser queimada sem a emissão de grandes quantidades de óxidos de nitrogênio (NO_x) e com baixa emissão de dióxido de enxofre (SO₂). Também podem ser aproveitados resíduos florestais, resíduos da agricultura e da indústria madeireira, com ampla utilização por importantes cadeias produtivas na Amazônia.

A região amazônica é rica em possibilidades de biomassa para combustível para produção de energia. Estudos anteriores apontaram para a utilização de resíduos de capoeira e de caroço de açaí (ROCHA e SILVA, 2000), (SILVA, ALMEIDA e ROCHA, 2004).

A biomassa ainda pode beneficiar as comunidades isoladas com geração de emprego e renda, pois podem ser feitas “florestas energéticas”, que se constituem de plantações com o fim específico de serem usadas como combustível. Tipos de vegetação especialmente úteis para essa finalidade, que se caracterizam por rápido crescimento e baixo valor comercial, vêm sendo estudados tendo em vista sua utilização.

1.5. O Projeto MEAPA.

Em 1996, uma parceria formada por algumas instituições europeias¹ decidiu investir em uma aplicação de planejamento energético em escala regional, que levasse em conta a abundância, localização geográfica, tecnologia disponível e custos de recursos eólicos e solares. Essencialmente, essa aplicação consistia de dois componentes: o primeiro fazia uma avaliação técnica e econômica das possibilidades de eletrificação rural, o segundo cuidava de criar cenários para a decisão, baseados em informações geográficas. Dessa forma, o

¹ CDEA (França), Conphoebus(Itália), CRES(Grécia), INESC(Portugal), RAL(Reino Unido e Irlanda)

componente formado por um Sistema de Informações Geográficas (SIG) era a grande novidade, que permitia um tratamento diferenciado, local e geograficamente integrado das informações. Essa aplicação ficou conhecida como Projeto SOLARGIS (MONTEIRO et al., 1998).

Baseado no sucesso dessa aplicação, em 1998, um convênio foi firmado pela Universidade Federal do Pará (UFPA), através do Centro Tecnológico/Departamento de Energia Elétrica com o Instituto de Engenharia de Sistemas e Computadores (INESC), de Porto, Portugal, para uma avaliação dos recursos energéticos renováveis no Arquipélago do Marajó, PA, com financiamento da Secretaria Executiva de Ciência, Tecnologia e Meio Ambiente (SECTAM), do Governo do Estado do Pará. Como o SOLARGIS só cuidava da energia eólica e solar, foi solicitado pela SECTAM que se incluísse um módulo de biomassa, dada a importância dessa fonte de energia renovável na região a ser estudada. Dessa forma, surgiu o projeto Metodologias Integradas para o Mapeamento de Energias Alternativas no Estado do Pará (MEAPA) cujo logotipo é visto na Figura 2, realçando a ênfase do planejamento energético para utilização de fontes renováveis de energia.



Figura 2 – Resultado do MEAPA mostrando potencial de biomassa no Marajó.

O objetivo do MEAPA era criar um conjunto de ferramentas para apoiar a integração das energias renováveis no Estado do Pará. Pretendia-se com este projeto construir uma base de informações geográficas para apoiar o planejamento energético da região; desenvolver metodologias integradas para dimensionamento e avaliação de soluções de eletrificação rural em áreas isoladas; implementar a metodologia em aplicações SIG - Sistemas de Informações Geográficas, mapear os recursos energéticos renováveis no Arquipélago do Marajó, conforme exemplo visto na Figura 3, de mapa de porcentual de dias com insolação no Marajó, e realizar testes da metodologia na região de estudo.

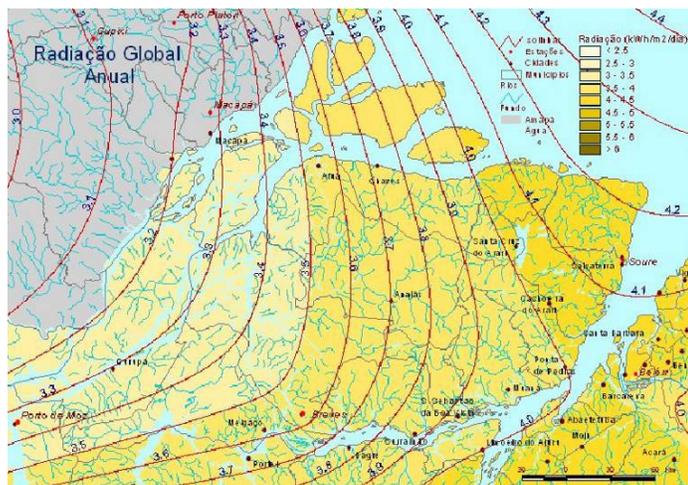


Figura 3 – Resultado do MEAPA mostrando porcentual de dias com insolação no Marajó.

Com base nos resultados desse trabalho, Silva (2003) estudou a sustentabilidade energética da Ilha do Marajó, com relação ao uso de energias renováveis, incluindo solar, eólica e biomassa, concluindo pela viabilidade do uso de biomassa como combustível primário para fornecimento de energia elétrica para grande parte dessas populações. Concluiu ainda, que haveria diminuição de emissão de CO₂, dada a substituição que ocorreria de equipamentos como gaseificadores usando biomassa em lugar de geradores diesel que existem atualmente.

Seria interessante que essa aplicação pudesse ser utilizada em outras áreas da região amazônica e, em particular do Estado do Pará. Ocorre, entretanto, que um inventário para se obter o potencial de biomassa na região amazônica é caro, com preços de mercado por volta de R\$ 10,00 (dez reais) por hectare para grandes áreas, como o Marajó. Além do custo financeiro, a região, pelas suas características geográficas, de florestas e grandes rios, oferece dificuldades e obstáculos imensos à realização de um levantamento desse porte. Considerando apenas a área do Arquipélago do Marajó, segundo o IBGE, incluindo 16 municípios (Cachoeira do Arari, Chaves, Muaná, Ponta de Pedras, Salvaterra, Santa Cruz do Arari, Soure, Afuá, Anajás, Breves, Curalinho, São Sebastião da Boa Vista, Bagre, Gurupá, Melgaço e Portel), com área de 49.606 km² (= 4.960.600 ha) esse inventário custaria em torno de 50 milhões de reais.

Portanto, mostra-se relevante a pesquisa de um método alternativo para a aquisição de potencial de biomassa, que possa fornecer resultados equivalentes, a um custo menor e que possa ser utilizado de forma mais cômoda e eficiente.

É o objetivo deste trabalho, propor uma metodologia integrada que utiliza tecnologia de redes neurais artificiais para extrair informações sobre potencial energético de biomassa a partir de imagens de satélite, combiná-las com dados de inventário de campo e inseri-las em uma aplicação desenvolvida em sistemas de informações geográficas.

Com isso, esse sistema informatizado de planejamento energético com energias renováveis terá uma utilização maior e poderá contribuir para a eletrificação rural de comunidades isoladas da Amazônia.

1.6. Trabalhos Relacionados.

O método mais preciso para se obter resultados confiáveis em um inventário florestal é usar dados coletados em campo e calcular o volume de biomassa a partir de equações alométricas, baseadas em medidas de altura da árvore e diâmetro do fuste medido à altura do peito. Entretanto, a possibilidade de fazer estimativa do volume de biomassa a partir de dados de sensoriamento remoto, tem atraído muita pesquisa nessa área, especialmente pela expectativa de redução de tempo e custo na obtenção dos resultados.

A partir dos anos 90, pesquisadores têm usado técnicas de redes neurais artificiais na tarefa de reconhecimento de padrões em imagens e estimativa de biomassa florestal em substituição ou complemento às técnicas estatísticas, como a análise bayesiana e regressão.

Segundo Bettinger e Hayashi (2006), várias técnicas analíticas têm sido testadas para relacionar a energia eletromagnética capturada pelos sensores dos satélites com estimativas de biomassa acima do solo. Assim, foram usadas técnicas de regressão simples e múltiplas, pois elas utilizam toda a informação eletromagnética capturada pelos sensores. As técnicas estatísticas tradicionais pressupõem que tanto os dados dos sensores remotos como os coletados em campo possuem uma distribuição normal, que não existe colinearidade entre as variáveis estudadas e que os dados possuem uma correlação linear entre eles. Porém, tem sido verificado que raramente tais pressuposições acontecem. Por outro lado, as redes neurais artificiais assim como métodos do vizinho mais próximo independem dessas suposições, o que tem lhes atraído preferência por parte dos pesquisadores.

No Brasil, Nishida e Bastos (1998) utilizaram redes neurais com função de base radial (RBF) e redes de Kohonen para desenvolver um classificador híbrido para cobertura vegetal em imagens de satélite. Compararam os resultados com classificadores baseados em métodos estatísticos e concluíram sobre a superioridade das redes neurais nessa tarefa, com ganhos de qualidade de resposta e menor tempo de classificação.

Venturieri e Santos (1998) escreveram sobre o uso de técnicas de classificação de cobertura vegetal em imagens do LANDSAT usando redes neurais artificiais, comparando treinamento supervisionado e não-supervisionado na obtenção de resultados.

Jensen et al. (1999) usaram imagens do LANDSAT e índices de vegetação, obtidos por operações aritméticas entre os valores de refletância de diferentes bandas da imagem, para estimar volume de biomassa em uma região da Bacia Amazônica. Trabalharam com as bandas 1 a 4 juntamente com redes neurais artificiais que, segundo eles apresentaram um desempenho semelhante às técnicas estatísticas de regressão.

Frate e Solimini (2003, 2004) usaram redes neurais artificiais de múltiplas camadas, com treinamento de retro-propagação para estimativa de biomassa florestal, aplicando-as a imagens de sensoriamento remoto obtidas por radar em diferentes polaridades. Concluíram que os métodos baseados em redes neurais artificiais eram equivalentes aos métodos estatísticos de regressão linear e não linear para os dados estudados.

Zheng et al. (2004) utilizaram imagens de LANDSAT para fazer estimativa de biomassa acima do solo em uma área cultivada no Estado do Wisconsin, nos Estados Unidos. Eles utilizaram diversos índices derivados das várias bandas das imagens, medições feitas em campo e agrupamento das árvores de acordo com a idade de plantio. Não utilizaram redes neurais, mas apenas modelos matemáticos e estatísticos.

Freitas et al. (2005), desenvolveram índices de vegetação usando duas imagens do LANDSAT, uma da estação seca e outra da estação chuvosa da Amazônia, para determinar se havia alguma correlação entre a estrutura da vegetação e os dados das imagens.

Ingram et al. (2005) usaram as bandas 3, 4, 5 e 7 do LANDSAT TM juntamente com índices derivados das bandas 3 e 4 para estimar biomassa em uma floresta tropical em Madagascar. Utilizaram uma rede neural artificial de múltiplas camadas com treinamento supervisionado do tipo retro-propagação. Concluíram haver uma forte correlação entre a resposta espectral e os valores coletados em campo em todas as faixas espectrais.

Saatchi et al. (2006) estudaram a distribuição da biomassa florestal na Bacia Amazônica com o duplo objetivo de mapear espacialmente a floresta e medir o fluxo de carbono na região. Utilizaram para isso cerca de 500 medições em diferentes áreas da Bacia Amazônica, junto com dados de sensoriamento remoto. Com uma margem de erro de $\pm 20\%$, eles estimaram em $86 \times 10^{15} \text{g}$ a quantidade total de carbono na floresta da Bacia Amazônica, incluindo aí não somente a biomassa acima do solo, mas também a biomassa sob o solo. Não utilizaram técnicas de redes neurais, mas usaram métodos estatísticos de correlação entre dados de sensoriamento remoto e medições feitas em campo.

Lu et al. (2002), Lu (2006) em seus trabalhos, sugeriram que o uso das bandas do LANDSAT juntamente com índices de vegetação derivados por operações aritméticas entre os valores dessas bandas não são muito bons para se obter resultados de estimativa de biomassa. Em seu lugar, defenderam o uso de técnicas estatísticas de regressão.

Gjertsen (2007) descreveu um método de estimativa de biomassa florestal em uma região da Noruega, usando imagens de LANDSAT e o método estatístico do k-ésimo vizinho mais próximo. Concluiu que a correlação entre os valores das bandas espectrais da imagem e as variáveis da floresta que lhes interessavam se mostrou baixa e pouco relevante, com um erro considerado inaceitável.

Neste trabalho, o ponto central foi estabelecer uma relação funcional entre a energia eletromagnética captada pelos sensores dos satélites e as estimativas de potencial energético de biomassa feitas em campo. Estudos anteriores citados acima, mostram que esse relacionamento, feito apenas para volume de biomassa, não é simples nem linear, mas altamente não-linear e complexo. Além disso, por não ser expresso de forma algébrica fechada, mas apenas através de uma amostra tabular, impõe-se o uso de uma ferramenta eficiente de aproximação funcional a partir dessa amostra incompleta dos dados.

Tendo em vista esses requisitos, este trabalho estimou não apenas o volume de biomassa mas, agregando informações de poder calorífico obtidas em campo, com vegetação característica da floresta amazônica, derivou daí o potencial energético dessa biomassa, com o objetivo de usar essa informação para planejamento energético com recursos renováveis em atividades ligadas à tarefa de eletrificação de comunidades isoladas da Amazônia.

1.7. Organização do Trabalho

No capítulo 2 estão discutidos os conceitos sobre sensoriamento remoto, na parte que se refere às suas aplicações à cobertura vegetal, e também sobre sistemas de informações geográficas, como um sistema integrador de informações textuais, gráficas e numéricas referidas a um contexto geográfico e espacial.

No capítulo 3 estão descritos conceitos e técnicas relacionadas com as redes neurais artificiais, detalhando suas principais características e potencial de uso como aproximadoras de funções contínuas em um espaço n-dimensional.

No capítulo 4 estão descritas a metodologia integrada, que permitiu extrair conhecimento novo a partir de imagens de satélite e dados de inventário de campo, usando-se

a tecnologia de redes neurais e integrando esses resultados em um sistema de informação geográfica.

No capítulo 5 estão descritos a área de estudo e os resultados obtidos com o inventário florestal realizado na área e que serviu para treinamento da rede neural e para a validação dos resultados.

No capítulo 6 são apresentados os resultados obtidos com essa metodologia integrada para estimativa de potencial energético da biomassa para produção de energia elétrica, bem como a discussão e validação desses resultados.

No capítulo 7 são feitos comentários gerais, em termos de conclusão, sobre os assuntos abordados no trabalho.

No apêndice 1 estão relacionados todos os dados de inventário florestal coletados em campo e nos apêndices 2 e 3 estão mostrados todos os mapas com os resultados obtidos, tanto de volume de biomassa como de potencial bioenergético da região.

Capítulo 2

SENSORIAMENTO REMOTO E SIG

2.1 Sensoriamento Remoto com Imagens de Satélite.

Sensoriamento remoto é a ciência e a arte de aquisição de informação (espectral, espacial, temporal) a respeito de objetos materiais sem a necessidade de contato físico com o objeto de investigação (LILLESAND e KIEFER, 2004).

Como não há contato direto, deve ser encontrado um meio de se transferir informação através do espaço. Em sensoriamento remoto, isto é conseguido por meio da radiação eletromagnética, que é uma forma de energia que revela sua presença através de efeitos observáveis ao entrar em contato com a matéria. Os comprimentos de onda considerados cobrem um espectro que vai de 10^{-10} mm nos raios cósmicos até 10^{10} mm nas ondas usadas em radiodifusão.

Existem dois tipos de sensoriamento remoto, o ativo e o passivo. O sensoriamento remoto passivo usa sensores que detectam a radiação eletromagnética refletida ou emitida pelos objetos, enquanto que no ativo, os sensores detectam a radiação refletida a partir da energia irradiada por fontes internas, como é o caso do radar. Quanto à faixa do espectro onde atua, o sensoriamento remoto pode ser classificado em 3 tipos:

- 1) faixa do visível e do infravermelho refletido;
- 2) faixa do infravermelho térmico
- 3) faixa de micro-ondas.

A radiação que não é absorvida ou dispersa pela atmosfera pode alcançar e interagir com os objetos na superfície terrestre. Quando a energia incide nos objetos, três formas de interação podem ocorrer: (a) absorção, (b) reflexão e (c) refração. E essas três formas não se excluem, elas podem ocorrer em proporções variadas em cada tipo de objeto, dependendo do comprimento de onda e do material onde ela incide.

As folhas da vegetação possuem clorofila, substância química que absorve fortemente a radiação nos comprimentos de onda do vermelho e do azul, refletindo o verde. Além disso, estruturas internas das folhas saudáveis refletem de forma difusa o infravermelho próximo. É esse fato que sugere o uso desses dois comprimentos de onda, do verde e do infravermelho

próximo na confecção de índices, como o NDVI (*Normalized Difference Vegetation Index*), que relaciona as refletâncias nesses comprimentos de onda para obter informação sobre a condição da vegetação.

O NDVI é definido como segue, pela Equação 2:

$$NDVI = \frac{IVP - VER}{IVP + VER} \quad \text{Eq. 2}$$

IVP = DN (Digital Number) da banda do infravermelho próximo

VER = DN (Digital Number) da banda do vermelho.

Imagens de satélite são obtidas por sensores especiais montados em satélites girando na órbita terrestre. Neste caso, as imagens são compostas a partir de sinais elétricos derivados da luz do sol refletida pela superfície terrestre em combinação com a atmosfera.

Computacionalmente, essas imagens são armazenadas como matrizes de números, onde cada elemento da imagem (*pixel*) tem um valor proporcional à energia eletromagnética refletida ou emitida pela área da superfície terrestre correspondente.

As principais características associadas às imagens de satélite são o número e a largura de bandas do espectro eletromagnético utilizado (resolução espectral), a resolução radiométrica e o intervalo de tempo entre duas passagens do satélite pelo mesmo lugar (resolução temporal).

Na Tabela 1 são mostrados dados técnicos dos parâmetros do satélite LANDSAT, cujas imagens foram utilizadas neste trabalho.

Tabela 1 – Características Técnicas do Satélite LANDSAT (NASA, 2008)

Especificações	Faixas de Operação do Sensor
Bandas espectrais (em μm)	1 - 0,45-0,52 (Azul) 2 - 0,52-0,60 (Verde) 3 - 0,63-0,69 (Vermelho) 4 - 0,76-0,90 (Infravermelho próximo) 5 - 1,55-1,75 (Infravermelho médio) 6 - 10,4-12,5 (Infravermelho térmico) 7 - 2,08-2,35 (Infravermelho médio)
Resolução espacial (em m)	30
Resolução temporal	Um ciclo a cada 16 dias
Dimensões da imagem (em km)	170 x 183

As diferentes bandas das imagens possuem utilidades e usos diferentes. De acordo com Lillesand e Kiefer (2004), temos os seguintes usos principais para as imagens nas diversas bandas, principalmente no aspecto relacionado à vegetação.

A banda 1 (azul) é utilizada para discriminação da vegetação do solo, mapeamento de florestas, assim como para o estudo de águas costeiras.

A banda 2 (verde) é usada para medir a refletância do verde na vegetação assim como para verificar a saúde da floresta.

A banda 3 (vermelho) permite medir níveis de absorção de clorofila pelas plantas, contribuindo para a diferenciação de tipos de vegetação.

A banda 4 (infravermelho próximo) é muito utilizada para a identificação de tipos diferentes de vegetação, assim como para avaliar o potencial de biomassa.

Na Figura 4 é apresentado um gráfico com a resposta de uma área do entorno do Lago de Tucuruí, em três diferentes bandas, em porcentagem. Essas curvas foram construídas a partir do processamento de 3 bandas da imagem do LANDSAT. Nela, a curva em azul corresponde aos níveis de intensidade obtidos na banda 1, a curva em verde corresponde aos níveis de intensidade obtidos na banda 2 e a curva em vermelho corresponde aos níveis de intensidade obtidos na banda 3 da imagem.

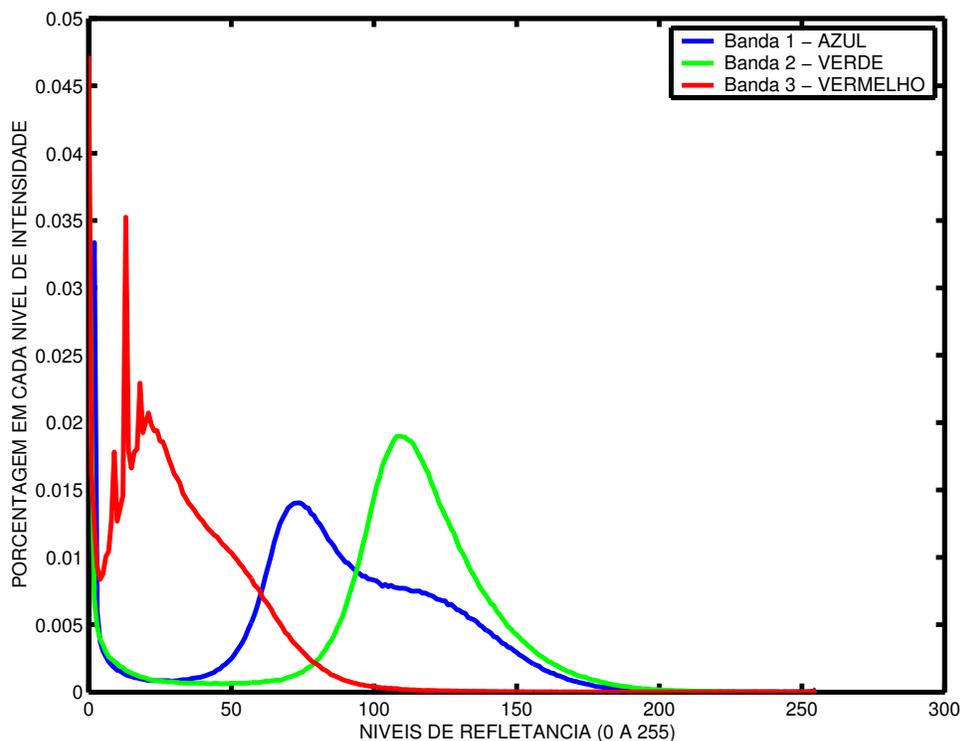


Figura 4 - Níveis de Intensidade nas bandas 1, 2 e 3 de uma imagem do LANDSAT da região do entorno do Reservatório de Tucuruí

Devido à natureza do processo de aquisição da imagem, os objetos geométricos ficam contidos na imagem, fazendo-se necessário o uso de técnicas de foto-interpretação ou de classificação automática digital para individualizá-los.

Atualmente, existem diversos algoritmos de classificação para levantamento, análise e monitoramento de uma paisagem florestal, permitindo extração de uma grande quantidade de informação relevante das imagens.

2.1.1. Sensoriamento Remoto da Vegetação.

Para este trabalho, interessou estudar a interação da energia eletromagnética com a vegetação, para que se possam obter parâmetros que caracterizem a sua presença e outras propriedades nas imagens de satélite.

Sabe-se que a clorofila, presente nas partes verdes das plantas, absorve fortemente a radiação eletromagnética nos comprimentos de onda do vermelho e do azul, mas reflete a radiação no comprimento de onda do verde. Por esse motivo, as folhas aparecem bem verdes nas imagens. Por outro lado, as estruturas internas das plantas atuam como refletores difusos dos comprimentos de onda do infravermelho refletido, ou infravermelho próximo. De fato, se nossos olhos fossem sensíveis ao infravermelho próximo, as plantas pareceriam muito brilhantes para nós nesses comprimentos de onda. Assim, as imagens obtidas nesse comprimento de onda são usadas para se avaliar o estado de uma plantação, pois a vegetação saudável o reflete de forma intensa.

Uma folha verde saudável intercepta o fluxo radiante (Φ_i) da luz do sol incidente ou da luz difusa na atmosfera. Essa energia incidente interage com os pigmentos, água e células no interior da planta. A quantidade de fluxo radiante refletido pela folha (Φ_r) a quantidade de fluxo radiante (Φ_a) absorvido pela folha e a quantidade de fluxo radiante (Φ_t) transmitido pela folha pode ser mensurado quando se leva em conta a equação do fluxo radiante e se pode verificar o que acontece com o total da energia incidente. Dessa forma, a equação geral que dá um balanço da energia espectral radiante que incide sobre a folha é dada pela equação (JENSEN, 2000):

$$\phi_i = \phi_r + \phi_a + \phi_t \quad \text{Eq. 3}$$

As razões $\frac{\phi_r}{\phi_i}$, $\frac{\phi_a}{\phi_i}$, $\frac{\phi_t}{\phi_i}$ entre cada uma das parcelas de energia e o fluxo total de energia incidente são chamadas, respectivamente, de refletância espectral, absorvância espectral e transmitância espectral da folha.

Assim, da equação 2 podemos afirmar que a refletância é igual à energia total recebida menos as energias absorvidas e transmitidas pela planta.

No que diz respeito à interação da vegetação com a radiação na faixa do infravermelho próximo, sabe-se que a refletância de uma folha verde saudável aumenta na faixa dos 700-1200nm. As folhas verdes saudáveis das plantas absorvem energia radiante de forma mais eficiente nas porções azul e vermelho do espectro, onde ela é necessária ao processo de fotossíntese. Entretanto, na faixa do infravermelho próximo, tanto a refletância como a transmitância assumem valores altos, pois é nessa faixa do espectro que se concentra a maior parte da energia solar incidente. Se as plantas absorvessem energia nessa faixa com a mesma eficiência com que absorvem a luz visível, elas estariam sobrecarregadas de energia e isso, possivelmente, danificaria seus tecidos. Assim, parece que as plantas desenvolveram mecanismos de adaptação para não absorverem essa imensa quantidade de energia que vem na faixa do infravermelho próximo, limitando-se a refletirem e a transmitirem essa energia (BECK, LIEN, SIMPSON, 1991).

2.1.2. *Classificação de Imagens de Satélite.*

Uso do solo se refere à utilização dada àquela faixa de terra, tais como agricultura, residência ou indústria, enquanto que *cobertura do solo* descreve o tipo de material que o reveste, tais como vegetação, rochas ou prédios. Assim, podemos ter uma cobertura de floresta, mas o seu uso pode ser extração de madeira, área de lazer ou área de proteção ambiental. Desta forma, para atividades de proteção ou planejamento ou fiscalização, é importante que se tenha uma classificação confiável da cobertura do solo, através de imagens de sensoriamento remoto, de satélite ou radar.

Algumas das razões pelas quais é importante uma boa classificação de imagens de sensoriamento remoto, no que diz respeito a uso e cobertura do solo são:

- Grandes áreas são registradas de forma fácil e repetitiva, ao longo de um intervalo de tempo.

- É possível a aquisição de imagens da área com a resolução necessária ao desenvolvimento da tarefa pretendida.
- Imagens de sensoriamento remoto evitam vários problemas de acesso por terra, principalmente em áreas como a Amazônia, onde esse acesso é dificultado por grandes rios e áreas de florestas.
- O custo com a aquisição e interpretação das imagens é menor do que um levantamento por terra.

Por outro lado, em alguns casos, a interpretação da imagem nem sempre cobre todos os aspectos necessários e algumas características não são percebidas pelo fato das imagens de sensoriamento remoto não possuírem uma outra perspectiva além da horizontal.

De acordo com Anderson (1976) um sistema adequado de classificação em vários níveis pode ser definido da maneira abaixo:

- 100 (área urbana ou construções)
 - 110 (residencial)
 - 120 (comercial e serviços)
 - 130 (industrial)
 - 140 (transportes)
 - 150 (comunicações e serviços públicos)
 - 160 (institucionais)
 - 170 (lazer)
 - 180 (uso misto)
 - 190 (terra nua urbana)
- 200 (área agrícola)
 - 210 (lavouras e pastos)
 - 220 (horticultura)
 - 230 (criação de gado)
 - 240 (outras áreas agrícolas)
- 300 (vegetação de savana)
 - 310 (gramíneas)
 - 320 (outras)
- 400 (área florestal)
 - 410 (floresta permanente)
 - 420 (floresta decídua)
 - 430
 - 440
 - 450
- 500 (Água)
 - 510

- 520
- 530
- 540
- 550
- 600 pântanos
 - 610
 - 620
 - 630
- 700 terra nua
 - 710
 - 720
 - 730
 - 740
- 800 tundra
 - 830
- 900 neve ou gelo
 - 910
 - 920

A categoria 100 (área urbana) compreende áreas de uso intensivo do solo, com a maior parte dele coberta por construções, ruas e estradas. O segundo nível de classificação detalha melhor a forma de utilização desses solos. É interessante notar que nesta categoria, quando se trata de um grande aglomerado urbano, outras categorias de nível 100 aparecem mescladas com a área urbana, como agricultura e água, nos arredores ou mesmo no meio das cidades.

Nas imagens do LANDSAT, essa categoria de solo, aparece como uma grande rede de ruas e estradas, muitas vezes mostrando um desenho irregular, principalmente nas cidades não planejadas. As áreas centrais, mais densamente povoadas aparecem em tons azulados por conta da ausência de vegetação e predominância de telhados e asfaltamento das vias. Já as áreas suburbanas das grandes cidades aparecem em tons avermelhados causados por um pequeno volume de vegetação, praças e parques.

A categoria 200 (área agrícola) é facilmente reconhecida quando ela está disposta em padrões regulares, tais como áreas retangulares ou mesmo circulares. Também áreas de desmatamento, principalmente na Amazônia, já possuem uma espécie de assinatura espectral, pois aparecem claramente como “espinhas de peixe” vermelhas misturadas ao verde da floresta densa.

A categoria 300 (savanas), ou também pequenas capoeiras em nossa região, é formada principalmente por gramíneas, pequenos arbustos e pastos onde é possível criação de gado, facilmente visíveis em imagens da região amazônica.

A categoria 400 (área florestal) caracterizada por áreas densamente verdes nas imagens coloridas, indica a presença de grandes árvores, com copas claramente visíveis, com possível produção de madeira, ou áreas de proteção ambiental.

A categoria 500 (águas) é fácil de ser reconhecida em imagens coloridas de satélite. Elas ficam bem definidas nas imagens da região amazônica. O grande reservatório de Tucuruí no Pará, por exemplo, possui um contorno escuro, devido à absorção da radiação eletromagnética, facilmente distinguível da floresta de seu entorno.

Na Figura 5, vemos uma imagem do LANDSAT, dos arredores de Belém, onde se podem distinguir diferentes tipos de cobertura do solo, tais como vegetação e áreas agrícolas, em tons de verde, rios, em cor escura e área urbana em vermelho.



Figura 5 - Imagem do LANDSAT do entorno de Belém, destacando-se diferentes tipos de cobertura do solo (INPE, 2007)

A tarefa de classificação de imagens de satélite pode ser feita de forma manual, por especialistas, mas considerando-se a grande quantidade de informação disponível e a urgência da disponibilidade dessa informação, cada vez mais está sendo feita por programas de computador, a partir de imagens digitais.

A classificação digital de imagens consiste basicamente em um reconhecimento automático de grupos de pixels. A classificação de imagem é feita usualmente utilizando-se informações de várias bandas de forma simultânea. Ela consiste, essencialmente em atribuir a cada pixel uma pertinência a uma dada classe de objetos, tais como vegetação, solo, área urbanizada, de acordo com o valor da refletância e informações sobre textura da região onde está o pixel (CCRS, 2000).

As duas formas básicas de classificação digital de imagem são a supervisionada e a não-supervisionada. Na primeira, ocorre a interação com um especialista, na segunda, apenas o programa decide sobre a classificação da imagem, a partir de dados do contexto.

A classificação de imagem digital usa a informação espectral representada pelos DN (*digital numbers*) de cada pixel em uma ou várias bandas espectrais para atribuir esse pixel a uma dada classe de interesse. Esse tipo de classificação é conhecido como reconhecimento do padrão espectral. Como resultado, a imagem classificada fica dividida em várias classes temáticas, tais como água, vegetação, área urbanizada, sendo transformada essencialmente em um mapa temático.

É bom esclarecer que quando falamos de classes podemos nos referir às classes de informação e às classes espectrais. As classes de informação são aquelas categorias que interessam ao classificador, tais como diferentes tipos de vegetação, tipos de rochas ou terrenos geológicos. Já as classes espectrais dizem respeito aos valores de refletância dos pixels nas diferentes bandas do espectro. O objetivo da classificação é fazer um mapeamento entre essas classes espectrais e as classes de informação. Raramente ocorre um mapeamento um para um entre as classes de informação e as classes espectrais. Assim, por exemplo, na classe de informação “floresta”, pode ocorrer várias subclasses que diferem quanto ao tipo ou idade da vegetação.

Na literatura existem descrições de vários algoritmos de classificação digital, a maioria deles baseados em métodos estatísticos e os mais recentes em redes neurais, algoritmos genéticos e lógica fuzzy. No entanto, verifica-se (BISHOP, 1995) que o problema de classificação de padrões, é uma extensão do problema de regressão linear e não-linear. E que os dois são casos particulares do problema de aproximação de funções em um espaço multidimensional. Portanto, para encontrar uma melhor solução para essa classe de

problemas, a melhor ferramenta é aquela que usar a melhor técnica de aproximação de funções. Ainda segundo Bishop (1995) as funções de base radial, que serão usadas neste trabalho, constituem a melhor ferramenta para aproximação de funções, interpolação com ruído nos dados, estimativa de densidade probabilística e teoria da classificação ótima.

2.2 Sistemas de Informações Geográficas (SIG)

Sistemas de Informações Geográficas (SIG) são sistemas de informações que manipulam banco de dados geográficos, isto é, banco de dados que além das informações convencionais, armazenam também as coordenadas geográficas da informação (KORTE, 2000).

Segundo Sabins (1996) um Sistema de Informações Geográficas (SIG) é uma coleção organizada de pessoas, equipamentos e programas de computador que coletam, armazenam, processam, analisam e visualizam todas as formas de dados referenciados geograficamente.

Com isso, ele permite que sejam feitos diversos tipos de análise estatística e espacial sobre os dados.

Em um sistema SIG, todos os dados estão geo-referenciados, isto é, possuem a informação das coordenadas geográficas referentes ao globo terrestre.

Em função disso, muitas aplicações de SIG são possíveis. Podemos dividi-las em três classes principais:

- (a) como ferramenta para produção de mapas;
- (b) como suporte para análise espacial de fenômenos;
- (c) como uma aplicação vinculada a um banco de dados geográficos, permitindo armazenamento e recuperação de informação espacial.

De acordo com Câmara e Medeiros (1998) os sistemas de SIG utilizam técnicas matemáticas e computacionais para o tratamento de informações geográficas. Esta tecnologia tem influenciado de maneira crescente as áreas de Cartografia, Análise de Recursos Naturais, Transportes, Comunicações, Energia e Planejamento Urbano e Regional (CÂMARA e MEDEIROS, 1998).

Junto com as preocupações ambientais, na atividade mesma do planejamento energético, veio a necessidade da abordagem integrada desse planejamento, uma vez que a existência do ser humano e suas ações estão fortemente condicionadas aos elementos naturais

que compõem o mundo fisiográfico e dependentes de um convívio com a Natureza, que cada vez mais lhe impõe uma conduta harmoniosa com o meio ambiente.

Assim, ao se buscar ferramentas tecnológicas adequadas ao planejamento energético que levassem em conta essa interação geográfica do homem com o seu ambiente, surge naturalmente a opção pelos Sistemas de Informações Geográficas (SIG) uma vez que eles, além de darem o tratamento clássico às informações, também levam em conta, através de bancos de dados geográficos, os diversos e importantes relacionamentos topológicos e espaciais entre os dados, permitindo que modelagens mais abrangentes sejam feitas com mais realismo e facilidade.

A principal característica de um SIG é a sua fácil integração de dados tradicionais, comerciais, demográficos e outros, com a informação geográfica pertinente, permitindo assim análises e modelagens que, sem essa ferramenta, seria virtualmente impossível de ser feita.

O termo Sistema de Informações Geográficas (SIG) refere-se àqueles sistemas que realizam tratamento computacional de dados geográficos. Um SIG armazena a geometria e os atributos de dados que estão geo-referenciados, isto é, localizados na superfície terrestre, em uma projeção geográfica dada.

Para cada objeto geográfico, um SIG necessita armazenar seus atributos e as várias formas de representações gráficas associadas, vetoriais ou raster. Devido a sua ampla gama de aplicações, onde estão incluídos temas como cobertura vegetal, agricultura, solo, recursos naturais, população, recursos energéticos, há pelo menos três grandes maneiras de se utilizar um SIG:

- (a) como ferramenta para produção de mapas;
- (b) como suporte informatizado para análise espacial de fenômenos;
- (c) como um banco de dados geográficos, com funções de armazenamento e recuperação de informação espacial.

Um SIG trabalha normalmente com as seguintes classes de dados:

- (a) mapas temáticos;
- (b) mapas cadastrais;
- (c) redes;
- (d) imagens;
- (e) modelos numéricos de terrenos.

Os mapas podem ser representados computacionalmente de duas formas:

- (a) a representação matricial, onde o espaço geográfico é representado por uma matriz $M(m,n)$. composta de m linhas e n colunas, onde cada célula possui um número de linha, um

número de coluna e um valor correspondente ao atributo estudado. Além disso, cada célula é acessada por seu endereço matricial único.

(b) a representação vetorial, onde são utilizados 3 tipos de elementos gráficos, ponto, linha e polígono (ou área). Nesta representação é essencial o conhecimento das relações topológicas entre os componentes, tais como proximidade, adjacência e pertinência.

Já os modelos numéricos de terreno podem ser representados computacionalmente como:

- (a) grade regular, que é uma representação matricial, onde cada elemento da matriz está associado a um valor numérico correspondente ao atributo estudado.
- (b) grade triangular, (ou TIN, triangular irregular networks), que representa uma superfície através de uma rede de faces triangulares interligadas.

Diferentes tipos de consultas podem ser feitos, cruzando os diferentes temas relativos a uma dada região. Essas consultas tanto podem fornecer conjuntos de dados alfanuméricos, como também informações geográficas e espaciais. Além dessas consultas, os SIG possuem linguagens de programação que permitem o desenvolvimento de aplicativos complexos envolvendo diversas análises contidas no banco de dados geográficos.

Uma aplicação típica em SIG consiste dos seguintes passos:

- *Coleta e compilação dos dados.* Esta fase consiste na coleta, organização e eventual digitalização dos dados a serem usados. Compreendem mapas impressos, dados coletados em campo em formato tabular ou mesmo de texto, imagens de satélite em várias bandas e resoluções, de acordo com a necessidade do projeto. Esta é, em geral, a fase mais demorada e custosa do processo, pois quase sempre envolve coleta de dados em campo, muitas vezes de forma onerosa e difícil. Uma dificuldade adicional nesta fase é compatibilizar os dados que normalmente vêm em diferentes formatos, resoluções e escalas.
- *Geo-referenciamento dos dados.* Para que os dados sejam processados em um SIG, eles devem se referir de forma precisa a algum ponto ou região na superfície da Terra. Por isso é necessário que os dados a serem utilizados possuam coordenadas geográficas válidas e consistentes associadas a eles. Essas coordenadas geográficas precisam ser coletadas em campo, no local de estudo em pontos estrategicamente escolhidos para sua validação. Além disso, mesmo dados geo-referenciados, às vezes, ainda precisam ser compatibilizados, pois estão em sistemas diferentes de coordenadas, como UTM (Universal Transverse Mercator) e Lat-Lon (Latitude-Longitude), por exemplo.

- *Geração de atributos.* Atributos são conjuntos de dados que ajudam a descrever uma feição da região em estudo: tipo de vegetação, mapa de elevação do terreno, distribuição de população, volume de biomassa ou potencial energético da biomassa são exemplos de atributos de uma área. Um mapa, em geral, se compõe de um agregado de atributos, cada um deles definindo uma característica diferente da região.
- *Análise dos dados.* É nesta fase que é feita a execução dos programas característicos de um SIG. Análises espaciais, geográficas e estatísticas são usadas para compreensão do fenômeno em observação. Também, nesta fase, normalmente os dados são classificados usando-se diversos algoritmos para a produção de dados agrupados segundo características pré-definidas. Essas classificações podem ser feitas de forma supervisionadas, interativamente, com um especialista ou de forma não-supervisionada, exclusivamente pelo programa, baseado nas características internas dos próprios dados.
- *Visualização dos resultados.* A visualização usual dos resultados em um SIG costuma vir em forma de tabelas e mapas, de densidade, distribuição, com cores diversas mostrando as diferentes características dos agrupamentos encontrados, relacionados com a localização geográfica.

Capítulo 3

REDES NEURAIIS ARTIFICIAIS

3.1 Redes Neurais Artificiais

A maior parte das atividades de processamento de informação em nossa sociedade tecnológica é executada por computadores digitais. Isso pode nos induzir à falsa crença de pensar que a capacidade de processamento de informação depende somente de processadores digitais.

Entretanto, em uma análise mais apurada, vemos que os organismos vivos, em suas estratégias de sobrevivência, dispõem de impressionante capacidade de processamento de informação, em tempo real, por meios não digitais.

A partir dessa constatação, pesquisas foram feitas, notadamente a partir dos anos 60 do século passado, para a obtenção de sistemas de processamento de informação diferentes daqueles usados pelos computadores digitais e inspirados diretamente no suposto funcionamento dos cérebros dos seres vivos.

As redes neurais artificiais (RNA), ou simplesmente redes neurais, surgiram dessas tentativas de se criar sistemas de processamento de informação modelados a partir do funcionamento do cérebro humano.

Uma rede neural biológica consiste de vários neurônios, bilhões deles no caso do cérebro humano, interligados. Visto como uma unidade de processamento de informação, um neurônio biológico possui uma entrada, os dendritos, o corpo da célula, onde ocorre o processamento, um filamento, chamado axônio e as saídas, as sinapses. A atividade neuronal ocorre entre neurônios próximos, através do axônio, usando processos eletro-químicos envolvendo troca de íons e difusão de moléculas de neurotransmissores (BECK, LIEN, SIMPSON, 1991).

Ainda segundo (BECK, LIEN, SIMPSON, 1991) um impulso nervoso consiste de uma zona de mudanças variáveis de potencial elétrico entre as superfícies interna e externa da membrana plasmática. Em um neurônio, a resposta a estímulos externos é do tipo sim ou não, isto é, ou o neurônio dispara um pulso elétrico para os neurônios próximos, ou não. Estímulos

abaixo de certo valor não vão fazer com que o neurônio dispare, enquanto que estímulos que ultrapassam um valor limite vão provocar o disparo do neurônio.

Redes neurais artificiais são sistemas de processamento de informação formados pela interconexão de unidades simples de processamento, denominadas neurônios artificiais. Os neurônios artificiais recebem essa denominação porque foram criados a partir de um modelo matemático simplificado de um neurônio biológico. Portanto, uma rede neural artificial é um dispositivo não-linear, com processamento paralelo, matematicamente funcionando como aproximador universal de funções (HAYKIN, 2001).

O processo computacional pelo qual uma RNA opera é definido da seguinte forma: um neurônio artificial ou elemento computacional recebe entradas de outros neurônios ou sinais do mundo externo. Uma soma ponderada dessas entradas constitui o argumento de entrada para a ativação de uma função de transferência. Essa função de transferência é, em geral, não linear, sendo a sigmóide uma das mais usadas. O valor resultante da aplicação dessa função ao argumento de entrada é a saída do neurônio. Essa saída, por sua vez, será distribuída através de conexões ponderadas para outros neurônios, ou para o mundo externo. (VEMURI, 1992).

A característica que torna atraente o uso de uma rede neural é a sua capacidade de aprendizagem. Todo o conhecimento aprendido por uma rede se encontra armazenado nos pesos de suas interconexões. O valor de um peso representa a força da associação, isto é, a ocorrência simultânea de conceitos, proposições ou eventos durante a fase de treinamento.

Redes neurais artificiais têm sido usadas com sucesso em diferentes áreas da tecnologia, tais como processamento de imagem, processamento de sinais, aproximação de funções e controle.

Em processamento de imagens, são comuns as aplicações de segmentação, classificação de imagens e reconhecimento de padrões. Nesta última área, existem aplicações para reconhecimento de caracteres escritos manualmente. Também são conhecidas aplicações para detecção de bordas, realce e compressão de imagens.

Em processamento de sinais, elas são usadas para acompanhar e distinguir múltiplos objetos em uma imagem de radar, classificar objetos a partir de sinais de sonar, sintetizar sons da fala humana e interpretar dados sísmicos.

Em controle, elas têm sido usadas por sua habilidade em calcular o estado atual de um sistema e seu ambiente, determinar uma estratégia para direcionar o sistema para um estado futuro desejado e implementar essa estratégia, manipulando atuadores e outros dispositivos de controle (WERBOS, 1992).

3.2 Processos de Aprendizagem em uma Rede Neural Artificial

Segundo Haykin (2001):

“Aprendizagem é um processo pelo qual os parâmetros livres de uma rede neural são adaptados através de um processo de estimulação pelo ambiente no qual a rede está inserida. O tipo de aprendizagem é determinado pela maneira pela qual a modificação dos parâmetros ocorre”.

Isso significa, ainda segundo (HAYKIN, 2001) que para que ocorra aprendizagem em uma RNA, é necessário que (a) a rede seja estimulada pelo ambiente externo, (b) que ela sofra modificação em seus parâmetros livres como resultado dessa estimulação pelo ambiente e que (c) devido às modificações, a rede responda de uma maneira diferente ao ambiente, por força das mudanças havidas em seus parâmetros livres.

Conforme Egmont-Petersen et al. (2002), diferentes arquiteturas de redes neurais existem em função de suas diversas finalidades. Quanto ao tipo de treinamento, ou aprendizagem, elas podem ser classificadas em supervisionadas e não-supervisionadas. As primeiras, entre elas as de retro-propagação (*back-propagation*), usam uma amostra dos dados para treinamento, comparando valores de saída da rede com valores esperados conhecidos, adaptando, a partir do erro, os valores de seus pesos, mediante certos algoritmos estabelecidos na literatura. As segundas, como as redes competitivas e as redes de Kohonen, não dispõem de valores de referência para comparação. Ao contrário, essas redes ajustam seus pesos de acordo com os dados de entrada, sem a pressuposição da existência de uma distribuição probabilística subjacente aos dados, como ocorre nos métodos estatísticos.

3.2.1 Aprendizagem por correção de erro.

A aprendizagem por correção de erro, cujo esquema pode ser visto na Figura 6, uma das primeiras a ser usada, é conhecida na literatura como regra delta, ou regra de *Widrow-Hoff*, (WIDROW e HOFF, 1960) em homenagem aos seus criadores, Widrow e Hoff. Ela pode ser formulada da seguinte maneira, pela Equação 4:

$$\Delta w_{ij} = (d_j - a_j) a_i \quad \text{Eq. 4}$$

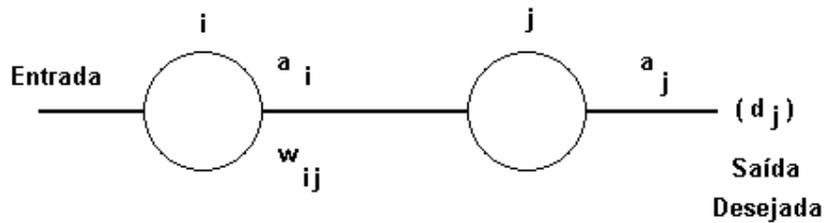


Figura 6 - Esquema da aprendizagem Widrow-Hoff

Os ajustes corretivos são projetados para o sinal de saída da resposta desejada e isto é conseguido minimizando-se a função erro quadrático dada pela equação

$$E(n) = \frac{1}{2} e_k^2(n) \quad \text{Eq. 5}$$

O processo de ajuste dos pesos sinápticos continua até que eles entrem em estado estacionário, quando então, acaba o treinamento.

Deste modo, de acordo com a regra delta, o ajuste a ser aplicado ao peso sináptico w_{ij} no tempo n é dado por:

$$\Delta w_{ij}(n) = \eta e_i(n) x_j(n) \quad \text{Eq. 6}$$

onde η é uma constante positiva, a taxa de aprendizado.

Assim, conforme Haykin (2001), a regra delta pode ser expressa como “o ajuste feito em um peso sináptico de um neurônio é proporcional ao produto do sinal de erro pelo sinal de entrada do neurônio”.

O algoritmo da retro-propagação (*backpropagation*) um dos mais usados em redes de múltiplas camadas, pode ser descrito como segue:

O algoritmo de retro-propagação é um algoritmo iterativo de treinamento de uma rede neural de múltiplas camadas projetado para minimizar o erro médio quadrático entre a saída desejada e o valor produzido pela rede. Ele requer que seja usada uma função não-linear que seja contínua e diferenciável no domínio pretendido pela aplicação. Uma das mais usadas na literatura é a função sigmóide, dada pela Equação 7:

$$f(x) = \frac{1}{1 + e^{-x}} \quad \text{Eq. 7}$$

O fluxograma básico do algoritmo envolve 5 passos (R1 a R5) descritos abaixo:

R1. Inicializar pesos.

Atribuir pequenos valores aleatórios a todos os pesos da rede.

R2. Apresentar valores de entrada e de saída.

Introduzir na rede o vetor de entradas (Equação 8)

$$[x_0, x_1, x_2, \dots, x_{n-1}] \quad \text{Eq. 8}$$

e as saídas desejadas

$$[d_0, d_1, d_2, \dots, d_{n-1}] \quad \text{Eq. 9}$$

O vetor de saída consiste de elementos de um conjunto de treinamento obtido a partir do total do conjunto dos dados.

R3. Calcular o valor das saídas.

Usar as funções sigmóides e as somas ponderadas para calcular o vetor de saída

$$[y_0, y_1, y_2, \dots, y_{n-1}] \quad \text{Eq. 10}$$

R4. Ajustar os pesos.

Usar um algoritmo recursivo para ajustar os pesos começando nos nós de saída da rede e caminhando para trás até a primeira camada oculta de neurônios. Ajustar os pesos com a Equação 11

$$w_{ij}(t+1) = w_{ij}(t) + \eta \delta_j x_j \quad \text{Eq. 11}$$

onde w_{ij} é o peso do nó da camada oculta i ou de uma entrada para o nó j no tempo t , x ou é uma saída do nó i ou é uma entrada, η é um fator de ganho e δ_j é um fator de erro para o nó j . Se o nó j for um nó de saída, então temos, pela Equação 12

$$\delta_j = y_j(1 - y_j)(d_j - y_j) \quad \text{Eq. 12}$$

onde d_j é a saída desejada para o nó j e y_j é o valor real da saída. Por outro lado, se o nó j for um nó de uma camada oculta, então, usando a Equação 13

$$\delta_j = x_j(1 - x_j) \sum_k \delta_k w_{jk} \quad \text{Eq. 13}$$

onde a somatória deve ser tomada sobre os k nós anteriores ao nó j .

R5. Retornar para o passo R2.

3.2.2 *Aprendizado Competitivo.*

No aprendizado competitivo, os neurônios de saída de uma rede neural competem entre si para serem ativados (HAYKIN, 2001).

No aprendizado competitivo, somente um neurônio é modificado para se assemelhar ainda mais ao valor de entrada do qual escolhido como o mais próximo.

A escolha do neurônio vencedor é feita levando-se em conta a distância euclidiana entre o vetor de entrada e cada nó de saída, de acordo com a equação. O neurônio vencedor é o que minimiza o valor de d_j dado pela Equação 14

$$d_j = \sum_{i=0}^{N-1} (x_i(t) - w_{ij}(t))^2 \quad \text{Eq. 14}$$

onde $x_i(t)$ é o valor de entrada para o nó i no tempo t e w_{ij} é o peso entre o nó de entrada i e o nó de saída j , no tempo t .

No aprendizado competitivo a arquitetura da rede pode possuir duas camadas: a camada de entrada que é constituída de unidades de processamento que recebem os padrões de entrada e a segunda camada que é a camada competitiva. As duas camadas são completamente interconectadas e cada conexão tem um peso associado. Na camada competitiva, as unidades competem pela oportunidade de responder ao padrão de entrada. A unidade vencedora neste caso representa a categoria de classificação do padrão de entrada. (LIPPMANN, 1992).

Na área de aprendizado competitivo existem vários modelos de algoritmos que embora similares em seus objetivos, diferem consideravelmente na maneira que trabalham. Um objetivo comum a esses algoritmos é distribuir certo número de vetores (quantização de vetores) em um espaço, geralmente, multidimensional. Espera-se com isso que esses vetores reflitam a distribuição de probabilidade dos dados de entrada que, em geral, não é dada explicitamente, mas apenas através de uma amostra de vetores (LIPPMANN, 1992).

3.3 RNA e Processamento de Imagens.

Inicialmente, processamento de imagens era feito exclusivamente com métodos estatísticos. Entretanto, a partir dos anos 80, com a criação do método de retro-propagação para treinamento de redes neurais de múltiplas camadas, tornou-se possível resolver os problemas envolvidos no processamento de imagens, com o uso de redes neurais artificiais (EGMONT-PETERSEN et al, 2002);

Esse algoritmo mostrou que era possível treinar de forma eficiente redes neurais com uma ou várias camadas ocultas e despertou o interesse da comunidade para o seu uso em vários problemas, incluindo processamento de imagem

Entre as arquiteturas de redes neurais mais utilizadas na área de processamento de imagem, despontam as redes multicamadas com treinamento de retro-propagação e o mapa auto-organizável (SOM) de Kohonen (KOHONEN, 1992).

Podemos dividir o problema de processamento de imagem em várias etapas, a saber:

- (a) *Pré-processamento e filtragem.* Nesta etapa, o algoritmo procura realçar e melhorar a imagem em questão.
- (b) *Análise de dados e extração de feições.* Como resultado deste processo, em geral temos uma imagem de tamanho menor e mais simples que a original.
- (c) *Segmentação.* Aqui a imagem é separada em diferentes regiões, de acordo com critérios pré-estabelecidos. Quando considerada como um processo de classificação, a segmentação trabalha diretamente com pixels da imagem, atribuindo a cada um deles uma classe de pertinência em um conjunto finito de classes. No caso de imagens de sensoriamento remoto, é costume a utilização de imagens obtidas nas diferentes bandas do espectro, o que facilita a sua classificação, pois a resposta a cada uma das bandas é, em geral, diferente para cada tipo de cobertura de solo, por exemplo.
- (d) *Reconhecimento de objetos.* Nesta etapa, os algoritmos devem ser capazes de reconhecer objetos, sua orientação, tamanho, escala e forma.
- (e) *Compreensão da imagem.* Compreensão semântica do conteúdo da imagem, para além dos objetos e relacionamentos.
- (f) *Otimização.* Uso de critérios que permitam, por exemplo, comparar uma imagem com outra, mesmo com ruído, e afirmar se elas são semelhantes ou não. Esse critério será o resultado da otimização de uma função de erro.

Segundo Egmont-Petersen et al (2002), as duas maiores vantagens de se usar as RNA ao processamento de imagem é que elas se aplicam a uma vasta classe de problemas e são de fácil implementação. Entretanto, alguns problemas devem ser levados em conta ao se usar uma RNA para essa tarefa. Um deles é o problema da dimensionalidade, que ocorre quando se tem muitas variáveis de entrada para serem apresentadas a uma rede classificadora. Esse problema decorre da inabilidade dos algoritmos classificadores operarem de forma estável com um grande número de parâmetros. Um outro, é garantir que uma rede treinada em um ambiente seja capaz de ser transferida para outro ambiente e ainda processar novos tipos de imagem de forma confiável.

Finalmente, as redes neurais sofrem de um problema chamado do “problema da caixa preta”, pois elas dão resultados, mas não fornecem explicações para a obtenção desses resultados.

Entretanto, para os objetivos deste trabalho, que é trabalhar com imagens de sensoriamento remoto, segundo Frate e Solimini (2003) o uso de redes neurais artificiais com dados de sensoriamento remoto tem se mostrado eficiente, uma vez que elas podem manusear simultaneamente uma aplicação não-linear de um espaço multidimensional em outro e lidar com complexos relacionamentos estatísticos.

3.4 RNA e Aproximação de Funções.

O problema do aprendizado de um mapeamento de um espaço de entrada em um espaço de saída é equivalente ao problema de sintetizar uma memória associativa que recupera a saída apropriada quando lhe é apresentada um exemplo conhecido de entrada e que generaliza quando um novo dado desconhecido de entrada lhe é apresentado (POGGIO e GIROSI, 1992). Portanto, ainda segundo Poggio e Girosi (1992), o contexto adequado para se estudar o aprendizado de redes neurais é o da teoria da aproximação de funções.

Assim, o problema da aproximação de funções pode ser posto nos seguintes termos: Se $f(X)$ é uma função contínua definida em um conjunto X e $F(W,X)$ é uma função aproximante, que depende de forma contínua de $W \in P$ e X então, o problema de aproximação consiste em determinar os parâmetros W^* e d uma função distância na métrica de X , tais que

$$d[F(W^*, X), f(X)] \leq d[F(W, X), f(X)], \text{ para todo } W \in P. \quad \text{Eq. 15}$$

Com essa definição, existem na literatura, soluções para as seguintes classes de funções:

- A função linear, $F(W, X) = W \cdot X$, com W e X vetores do espaço euclidiano n -dimensional, o que corresponde a uma rede neural sem camada oculta.
- A aproximação clássica linear em um conjunto de funções com uma base adequada é dada por

$$F(W, X) = \sum_{i=1}^M W_i G_i(X) \quad \text{Eq. 16}$$

onde $\{G(X)\}$ é uma base de funções dos pontos de entrada X . Esta equação corresponde a uma rede neural com uma única camada oculta. São exemplos deste caso, a interpolação com splines, as representações com bases de polinômios ortogonais e as séries truncadas de Fourier

- A aproximação por um conjunto de funções sigmóides aninhadas, que é equivalente a uma rede neural de múltiplas camadas, com treinamento por retro-propagação,

$$F(W, X) = \sigma\left(\sum_i w_i \sigma\left(\sum_j w_j \sigma\left(\dots \sigma\left(\sum_r u_r X_r\right)\dots\right)\right)\right) \quad \text{Eq. 17}$$

onde σ é uma função sigmóide. Esta equação corresponde a uma rede neural de múltiplas camadas, com neurônio usando funções sigmóides que computam somas ponderadas com seus pesos $W = \{w_i, w_j, \dots, w_r\}$ e, então aplica uma transformação sigmóide nessa soma ponderada (GRAUBE, 2007).

Uma rede neural de múltiplas camadas treinada com retro-propagação pode ser vista como um mapeamento não-linear de um espaço em outro. Segundo Haykin (2001), é possível considerar essa rede como um mapeamento não-linear especificado como segue: seja M o número de nós de entrada e N o número de nós de saída. Essa relação de entrada-saída define um mapeamento de um espaço euclidiano de M dimensões para um outro espaço euclidiano de N dimensões.

Um teorema importante, devido a Kolmogorov-Arnold (HAYKIN, 2001), na verdade o teorema fundamental deste assunto, o teorema da aproximação universal, é a base matemática que possibilita a aproximação de funções a ser desenvolvida mais adiante neste trabalho.

“Seja $g(x)$ uma função contínua, não constante, limitada e monotonamente crescente. Seja I_M o hipercubo unitário $[0,1]^M$, de dimensão M . O espaço das funções contínuas

em I_M , representado por $C(I_M)$. Então, dada qualquer função f em $C(I_M)$ e $\varepsilon > 0$, existe um inteiro M e conjuntos de constantes reais α_i , b_i e w_{ij} , onde $i=1,2,\dots,N$ e $j=1,2,\dots,m$, tal que podemos definir

$$F(x_1, \dots, x_m) = \sum_{i=1}^N \alpha_i g\left(\sum_{j=1}^m w_{ij} x_j + b_i\right) \quad \text{Eq. 18}$$

como uma realização aproximada da função f , isto é,

$$|F(x_1, x_2, \dots, x_m) - f(x_1, x_2, \dots, x_m)| < \varepsilon \quad \text{Eq. 19}$$

para todo x_i que se encontre no espaço de entrada”.

Como pode ser visto, o lado direito da equação é a expressão matemática de uma rede neural de múltiplas camadas, com m nós de entrada, uma única camada oculta com N neurônios e as entradas representadas pelos x_i . O neurônio oculto i tem pesos sinápticos w_{ij} e correção b_i . e a saída da rede é uma combinação linear das saídas dos neurônios ocultos, com os pesos sinápticos α_i , da camada de saída (HAYKIN, 2001).

O teorema da aproximação é importante do ponto de vista teórico, pois garante a existência de uma rede de múltiplas camadas que aproxima qualquer função contínua em um espaço euclidiano N -dimensional. Entretanto, o teorema nada afirma sobre se essa rede encontrada é a rede ótima ou não.

3.5 O Mapa auto-organizável de Kohonen ou Rede de Kohonen

Kohonen (1992), ao descrever sua arquitetura de rede, afirma que entre as arquiteturas e algoritmos sugeridos para redes neurais, o mapa auto-organizável (SOM, Self Organizing Map) possui a propriedade importante e especial de criar representações internas com organização espacial das várias características dos sinais de entrada e suas abstrações.

O mapa auto-organizável proposto por Kohonen é uma rede neural engenhosa constituída em torno de uma grade uni ou bi-dimensional de neurônios para capturar as características importantes contidas em um espaço de entrada de interesse. Dessa forma, uma vez treinada, ela fornece uma representação estrutural dos dados de entrada pelos vetores de pesos dos neurônios como protótipos. O algoritmo SOM é inspirado diretamente na

neurobiologia, incorporando todos os mecanismos que são básicos para a auto-organização: competição, cooperação e auto-amplificação, conforme veremos logo adiante no estudo do método de aprendizado dessa rede.

O Mapa Auto-Organizável de Kohonen ou rede de Kohonen, cujo esquema é visto na Figura 7, é uma rede neural artificial (RNA) com duas camadas, de treinamento não-supervisionado, entrada intervalar e conexão competitiva (HAYKIN, 2001), conforme visto na Figura 8. Diz-se que esse tipo de rede possui um paradigma topológico, uma vez que a rede pode apresentar qualquer formato geométrico bidimensional em sua camada de saída, como hexagonal, retangular, triangular e outros.

A motivação da rede de Kohonen decorre da descoberta de que o córtex cerebral humano aloca regiões específicas para atividades específicas e que, para uma determinada ativação cerebral, o grau de ativação dos neurônios diminuía à medida que se aumentava a distância da região de ativação inicial (KOHONEN, 1992).

Não há propriamente um reconhecimento de padrão como em outros modelos, mas há a classificação de um padrão junto com outros que têm características semelhantes, formando classes. Estas classes são organizadas num mapa, onde se pode observar a distribuição dos padrões. Desta maneira, no instante em que um padrão é inserido na rede, esta o coloca na classe onde melhor o padrão se ajusta, em função das suas características.

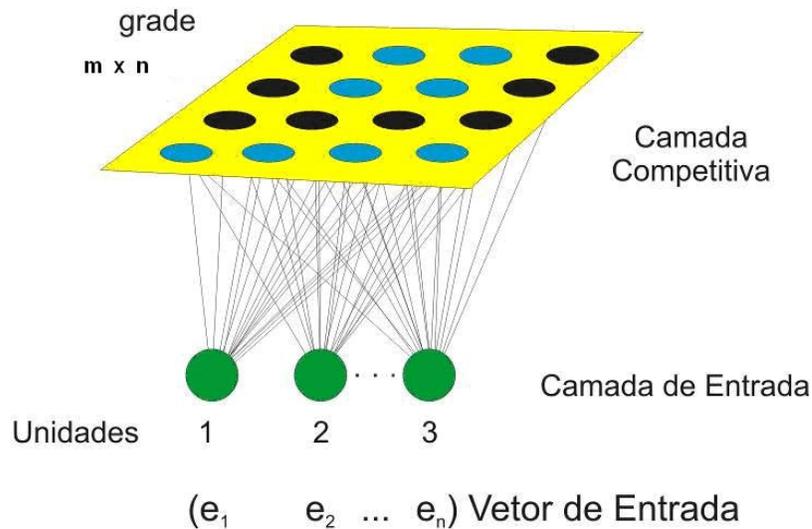


Figura 7 - Esquema de uma rede de Kohonen (HAYKIN, 2001).

3.5.1. Aprendizado em uma rede de Kohonen

O processo de aprendizado desta rede, segundo Kohonen (1992) aplica duas equações básicas, de acordo com as duas etapas de (a) determinar o neurônio vencedor e (b) modificação dos pesos do neurônio vencedor.

$$\|x(t) - m_c(t)\| = \min_i \|x(t) - m_i(t)\| \quad \text{Eq. 20}$$

$$\begin{cases} m_i(t+1) = m_i(t) + \alpha(t)[x(t) - m_i(t)], & \text{se } i \in N_c \\ m_i(t+1) = m_i(t), & \text{se } i \notin N_c \end{cases} \quad \text{Eq. 21}$$

onde, no tempo t ,

x é valor da entrada

m_i é um nó qualquer da rede

m_c é o neurônio vencedor

α é a taxa de aprendizagem

N_c é a vizinhança do neurônio vencedor.

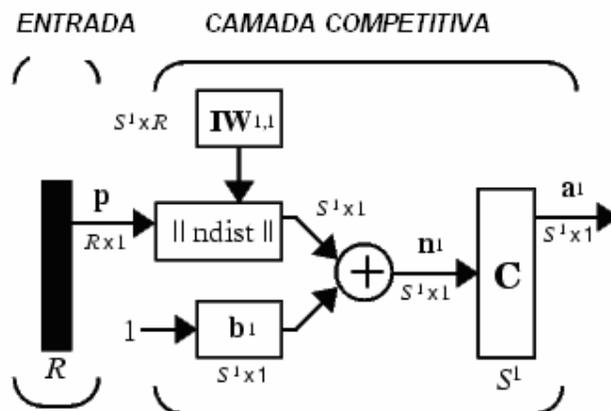


Figura 8 - Esquema de uma Rede Competitiva. Adaptado de Demuth e Beale (2002)

Durante o treinamento da rede os neurônios da camada de saída competem para serem os vencedores a cada nova iteração do conjunto de treinamento. Ou seja, sempre que é apresentada, à rede neural, uma entrada qualquer, existe uma competição entre os neurônios da camada de saída para representar a entrada apresentada naquele momento. Esse aprendizado, nada mais é do que modificações sucessivas nos pesos dos neurônios de forma que estes classifiquem as entradas apresentadas. O treinamento da rede neural terá sido efetivo quando ela reconhecer todas as entradas apresentadas durante a fase de treinamento.

Assim é que se traduz o aprendizado da rede neural, pois, havendo pelo menos um neurônio que represente uma determinada informação (um estímulo apresentado na entrada), sempre que este estímulo for apresentado a esta rede neural, aquele neurônio que foi treinado para representá-lo, automaticamente irá ser disparado, informando assim, qual o estímulo que foi apresentado para a rede neural.

As redes neurais têm a capacidade de reconhecer variações dos estímulos treinados. Isto significa, por exemplo, que apresentando um estímulo X qualquer, semelhante a um estímulo Y que fez parte do conjunto de treinamento, existe uma grande probabilidade de que o estímulo X seja reconhecido como o estímulo Y treinado. Revelando, dessa maneira, a capacidade de generalização da rede neural artificial.

O algoritmo para treinamento de uma rede de Kohonen consiste dos 6 passos (1 a 6) descritos a seguir:

1. Inicialização dos pesos, escolhidos aleatoriamente, com valores baixos da ordem de 0,001. Ajuste inicial do raio de vizinhança, que poderá começar com a metade do diâmetro da rede e ir diminuindo linearmente.
2. Inserção do padrão de entrada.
3. Cálculo das distâncias euclidianas para todos os nós. onde d_j é distância entre a saída do nodo j com a entrada, N é número de entradas, $e_i(t)$ é o vetor de entrada no tempo t e $p_{ij}(t)$ é o peso da conexão do neurônio de entrada i para o neurônio j no tempo t .

$$d_j = \sum_{i=1}^N (e_i(t) - p_{ij}(t))^2 \quad \text{Eq. 22}$$

4. Seleção do vetor com a menor distância. O vetor que apresentar a menor distância euclidiana, calculada no item anterior é selecionado para ser o neurônio vencedor.
5. Atualização dos pesos do neurônio vencedor e seus vizinhos, definidos pelo raio de vizinhança, como mostra a fórmula a seguir. Onde a equação $P(t+1)$ é o novo peso, $P(t)$ é o peso anterior, $\eta(t)$ é o fator de aprendizagem no tempo, que varia dessa forma: $\eta(t) = 0.9 (1 - t / 1000)$. E $E(t) - P(t)$ é a diferença vetorial entre o vetor de entrada e o vetor de pesos do neurônio vencedor. Uma observação importante é que os neurônios que não pertencem à vizinhança do vencedor não devem ter seus pesos atualizados.

$$P(t + 1) = P(t) + \eta(t)(E(t) - P(t)) \quad \text{Eq. 23}$$

6. Repetir até que o treinamento esteja terminado.

3.6 Redes RBF (Funções de Base Radial)

As redes RBF possuem, cujo esquema de funcionamento é visto na Figura 9, além das camadas de entrada e de saída uma única camada oculta, com neurônios possuindo funções de base radial como a gaussiana (HAYKIN, 2001). Elas são usadas em problemas de aproximação de funções, onde as funções de base radial formam uma base de funções convenientes para aproximação de outras funções em um espaço multidimensional (POGGIO e GIROSI, 1992).

Segundo Poggio e Girosi (1992), o problema de interpolação de uma hiper-superfície em um espaço multidimensional pode ser interpretado da seguinte forma:

Dados N diferentes pontos $(x_i \in \mathbf{R}^n, i=1,2,..N)$ encontrar uma função f de \mathbf{R}^n em \mathbf{R} , satisfazendo às condições de interpolação

$$F(x_i) = y_i \text{ com } i = 1, 2, \dots, N \quad \text{Eq. 24}$$

A solução com o uso de funções de base radial (RBF) consiste em escolher uma função $F(x)$ da seguinte forma

$$F(x) = \sum_1^N c_i h(\|x - x_i\|) + \sum_1^m d_i p_i(x), \text{ com } m \leq N \quad \text{Eq. 25}$$

onde h é uma função contínua de \mathbf{R}^+ em \mathbf{R} , usualmente chamada de *função de base radial*, quase sempre a gaussiana, no caso de redes neurais, $\|.\|$ é a norma euclidiana em \mathbf{R}^n e p_i é uma base de um espaço linear de polinômios, de grau no máximo $k-1$, de \mathbf{R}^+ em \mathbf{R} , e k é dado.

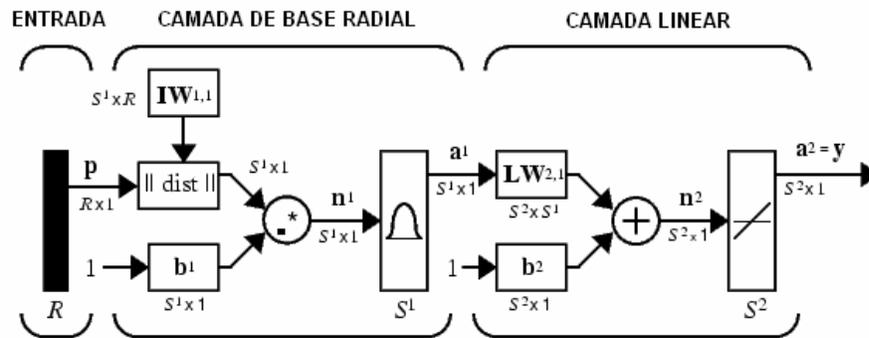


Figura 9 - Esquema de uma Rede RBF. Adaptado de Demuth e Beale (2002)

Onde:

$R = n^\circ$ de elementos do vetor de entrada .

$S^1 = n^\circ$ de neurônios na primeira camada.

$S^2 = n^\circ$ de neurônios na segunda camada.

As redes RBF estão associadas normalmente ao problema de interpolação de funções em um espaço de alta dimensão. Neste contexto, aprender é equivalente a encontrar uma superfície em um espaço de várias dimensões, que forneça o melhor ajuste para os dados de treinamento, com o critério de “melhor ajuste” sendo definido de forma estatística (POGGIO e GIROSI, 1992). Generalizar é equivalente ao uso dessa superfície para encontrar os dados correspondentes aos dados de entrada, isto é, interpolar. Como se sabe, as funções de base radial tem sido objeto de intensa pesquisa na solução do problema de interpolação (HAYKIN, 2001).

Segundo Chen et al. (1992), uma rede RBF, com entrada vetorial e saída escalar, pode ser formulada matematicamente como um mapeamento definido por:

$$f(X) = \lambda_0 + \sum_{i=1}^n \lambda_i G(\|X - c_i\|) \quad \text{Eq. 26}$$

onde $X \in R^n$, é um vetor de entrada, $G(\cdot)$ é uma função de R^+ em R , $\|\cdot\|$ é a norma euclidiana em R^n , λ_i , com $0 \leq i \leq n$, são os pesos ou parâmetros livres e $c_i \in R^n$, $0 \leq i \leq n$, são os centros da RBF, com n centros.

Assim como as redes de múltiplas camadas com retro-propagação, as redes RBF também possuem uma versão adaptada do teorema de aproximação universal, que é a seguinte:

(Teorema da Aproximação Universal para Redes RBF, (HAYKIN, 2001)).

“Para qualquer função contínua de mapeamento entrada-saída, $f(X)$, existe uma rede RBF com um conjunto de centros $\{c_i\}$ com $0 \leq i \leq m$ e uma largura $d > 0$, tal que a função de mapeamento de entrada-saída $F(X)$ realizada pela rede RBF, é tão próxima quanto se queira, na norma L_p , com $p \in [1, \infty]$.”.

Observa-se que as redes RBF e as redes de múltiplas camadas são, ambas, exemplos de redes alimentadas adiante, não-lineares. Como foi visto, são também aproximadores universais e, verifica-se, além disso, que sempre existe uma rede RBF capaz de se comportar como uma rede de múltiplas camadas e vice-versa (HAYKIN, 2001).

3.6.1 Aprendizado em uma rede RBF.

De acordo com Chen et al. (1992) a abordagem mais usada para implementar uma estratégia de aprendizado de uma rede RBF, baseada em seus princípios teóricos, consiste em assumir funções de base radial fixas nas unidades ocultas e escolher os centros de forma aleatória dentre os dados de treinamento.

Assim, uma função de base radial (RBF) com centro em t_i é definida por

$$G(\|X - t_i\|^2) = \exp\left(-\frac{m}{d^2} \|x_j - t_i\|^2\right), \quad i = 1, 2, \dots, m \quad \text{Eq. 27}$$

onde m é o número de centros e d é a distância máxima entre os centros escolhidos. Deve ser assegurado nessa escolha que as funções não fiquem nem muito pontudas (base estreita) nem muito planas (base muito larga), pois isso influencia a convergência.

Portanto, os únicos parâmetros a serem aprendidos nesta estratégia são os pesos lineares na camada de saída da rede. Para obtê-los, temos a equação:

$$W = G^{++} d \quad \text{Eq. 28}$$

Onde d é vetor resposta desejada do conjunto de treinamento e a matriz G^{+} é a pseudo-inversa da matriz G , definida por $G = \{g_{ij}\}$, onde

$$g_{ij} = \exp\left(-\frac{m}{d^2} \|x_j - t_i\|^2\right), \quad i = 1, 2, \dots, N, \quad j = 1, 2, \dots, m \quad \text{Eq. 29}$$

.com \mathbf{x}_j sendo o j -ésimo vetor de entrada do treinamento.

O método usado em álgebra linear para o cálculo da pseudo-inversa de uma matriz é o chamado método da decomposição em valores singulares.

Se \mathbf{G} é uma matriz real $n \times m$, existem as matrizes ortogonais $\mathbf{U} = \{\mathbf{u}_1, \mathbf{u}_2, \dots, \mathbf{u}_n\}$ e $\mathbf{V} = \{\mathbf{v}_1, \mathbf{v}_2, \dots, \mathbf{v}_m\}$, tais que

$$U^T G V = \text{diag}(\sigma_1, \sigma_2, \dots, \sigma_k), \text{ com } k = \min(m, n) \quad \text{Eq. 30}$$

onde $\sigma_1 > \sigma_2 > \dots > \sigma_k > 0$.

Os vetores colunas da matriz \mathbf{U} são os vetores singulares esquerdos e os vetores colunas da matriz \mathbf{V} são os vetores singulares direitos. Os valores $\sigma_1 > \sigma_2 > \dots > \sigma_k > 0$ são os valores singulares da matriz \mathbf{G} . Assim, de acordo com o teorema da decomposição em valores singulares, a pseudo-inversa $m \times n$ da matriz \mathbf{G} é dada por

$$\mathbf{G}^+ = \mathbf{V} \Sigma^+ \mathbf{U}^T \quad \text{Eq. 31}$$

onde Σ^+ é uma matriz $n \times n$ definida em termos dos valores singulares de \mathbf{G} , por

$$\Sigma^+ = \text{diag}\left(\frac{1}{\sigma_1}, \frac{1}{\sigma_2}, \dots, \frac{1}{\sigma_k}, 0, \dots, 0\right) \quad \text{Eq. 32}$$

O método de decomposição em valores singulares permite escrever a pseudo-inversa de uma matriz como uma soma de matrizes de posto 1, pois

$$G^+ = v_1 \sigma_1^{-1} u_1^t + v_2 \sigma_2^{-1} u_2^t + \dots + v_n \sigma_n^{-1} u_n^t$$

ou, de forma mais compacta $G^+ = \sum_{k=1}^N u_k \sigma_k^{-1} v_k^t$.

Como os valores principais estão ordenados de forma decrescente, $\sigma_1 > \sigma_2 > \dots > \sigma_k > 0$, é possível aproximar uma matriz usando apenas os seus valores principais que possuem o maior valor absoluto, que são os primeiros da seqüência. Isso facilita o cálculo da pseudo-inversa, além de aumentar a eficiência da convergência do aprendizado da rede RBF, contribuindo em muito pra diminuir tanto o tempo de treinamento da rede, como a memória necessária para armazenar essa informação. Além disso, essa propriedade abre grandes possibilidades de aplicações práticas, sendo a compressão de imagens digitais a mais importante delas (STRANG, 1988)

Capítulo 4

MATERIAL E MÉTODOS

4.1 Uma Metodologia Integrada

A metodologia proposta neste trabalho consiste em integrar os dados de sensoriamento remoto (imagens de satélite), extrair deles a informação relevante (redes neurais) e obter os resultados desejados (SIG):

- (a) Usar as coordenadas dos pontos de inventário e as imagens de satélite da região de estudo, no software SPRING, e criar uma planilha com os valores de refletância de cada um dos pontos inventariados, em cada uma das bandas 1, 2, 3 e 4, conforme mostrado na Figura 10.

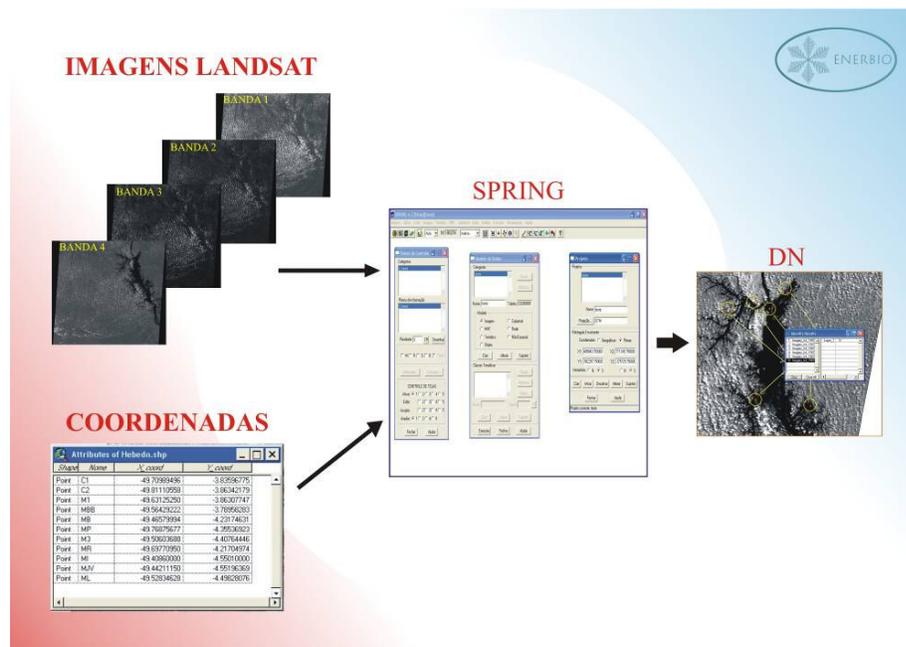


Figura 10 – Esquema de extração dos Dados da Imagem do LANDSAT com o Programa SPRING

- (b) Treinar uma rede neural RBF com uma amostra dos dados da planilha obtida no item (a), contendo os valores de refletância de alguns pontos de inventário, o valor da altura média das árvores na amostra, a área basal e o volume de biomassa derivados do inventário florestal. Na Figura 11, é vista a arquitetura da rede neural

RBF, mostrando as entradas, os neurônios da rede e sua saída. As etapas a, b e c foram feitas com programa codificado no ambiente de redes neurais do MATLAB (DEMUTH e BEALE, 2002).

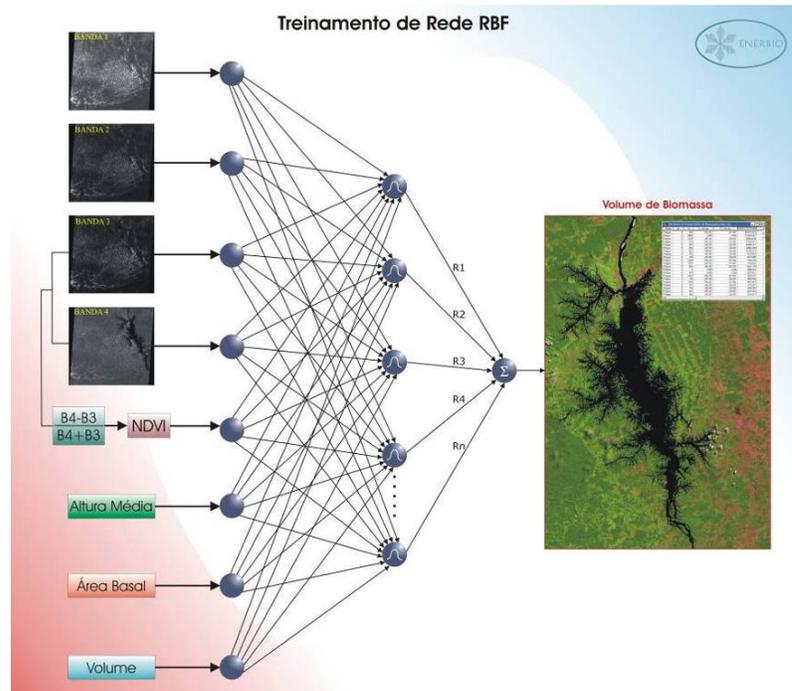


Figura 11 – Esquema de treinamento da Rede RBF

- (c) Estimar o potencial de biomassa de toda a região de estudo. A Figura 12 mostra como a simulação é feita, com a rede já treinada usando os dados de entrada e gerando os dados estimados de saída. Os dados de entrada agora são os mesmos do item anterior menos o volume, que será a saída da rede. Além disso, nesta etapa todos os dados são apresentados à rede para estimativa. Para isso será usada a imagem de satélite e a rede neural RBF treinada no item (b).

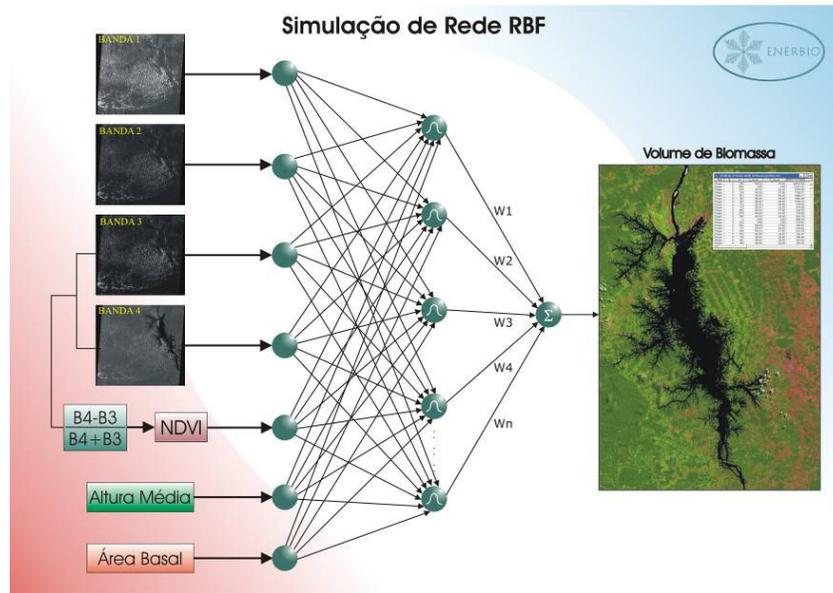


Figura 12 – Esquema de simulação de Rede RBF

- (d) Segmentar e classificar a imagem de satélite da região de estudo, com a rede neural de Kohonen, para se agrupar as áreas com valores semelhantes, obtidas no item anterior. A Figura 13 mostra o esquema de classificação e segmentação da imagem, feito pela rede de Kohonen.

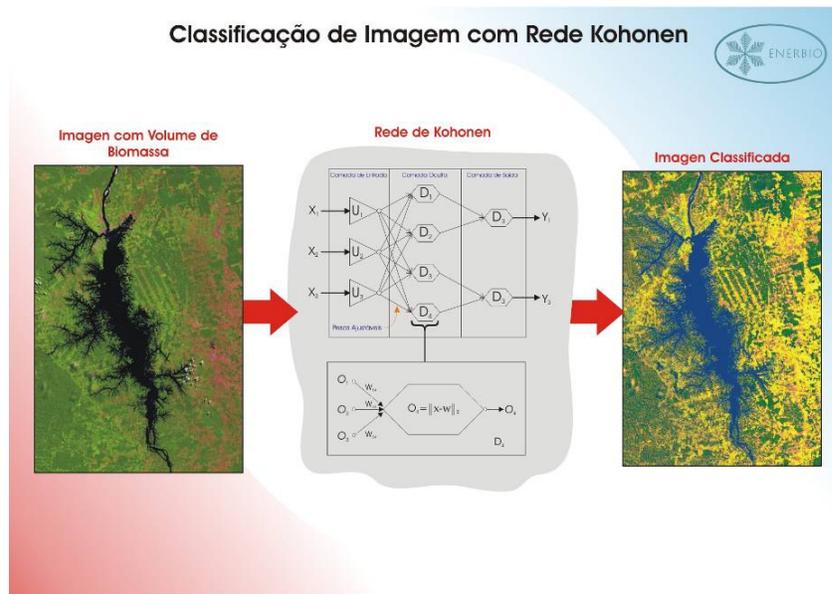


Figura 13 – Classificação de Imagem com Rede de Kohonen

- (e) Criar o banco de dados geográfico de volume de biomassa da região, incluindo mapa vetorial e tabela de valores no programa de SIG, ARCVIEW e executar a

aplicação que analisa esses dados e gera cenários diversos para apoio ao planejamento energético. Na Figura 14 é mostrado um diagrama de bloco do funcionamento dessa etapa: os dados de entrada gerados pela rede são introduzidos no sistema de informações geográficas, criando o banco de dados espacial.

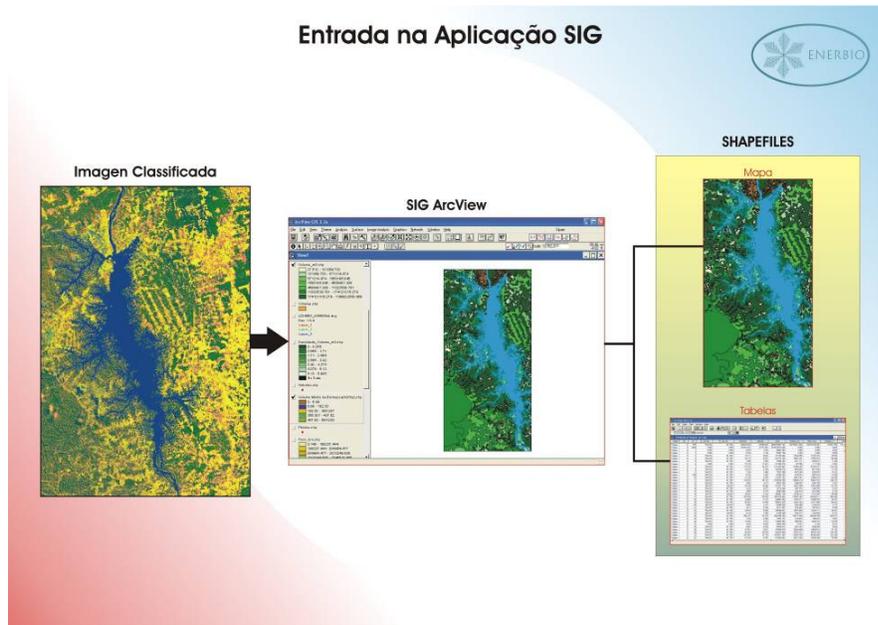


Figura 14 – Esquema da entrada na aplicação SIG

- (f) Processar o programa MEAPA e obter mapas temáticos e relatórios de apoio ao planejamento energético da região. A Figura 15 ilustra o funcionamento da aplicação MEAPA, com suas entradas e saídas.

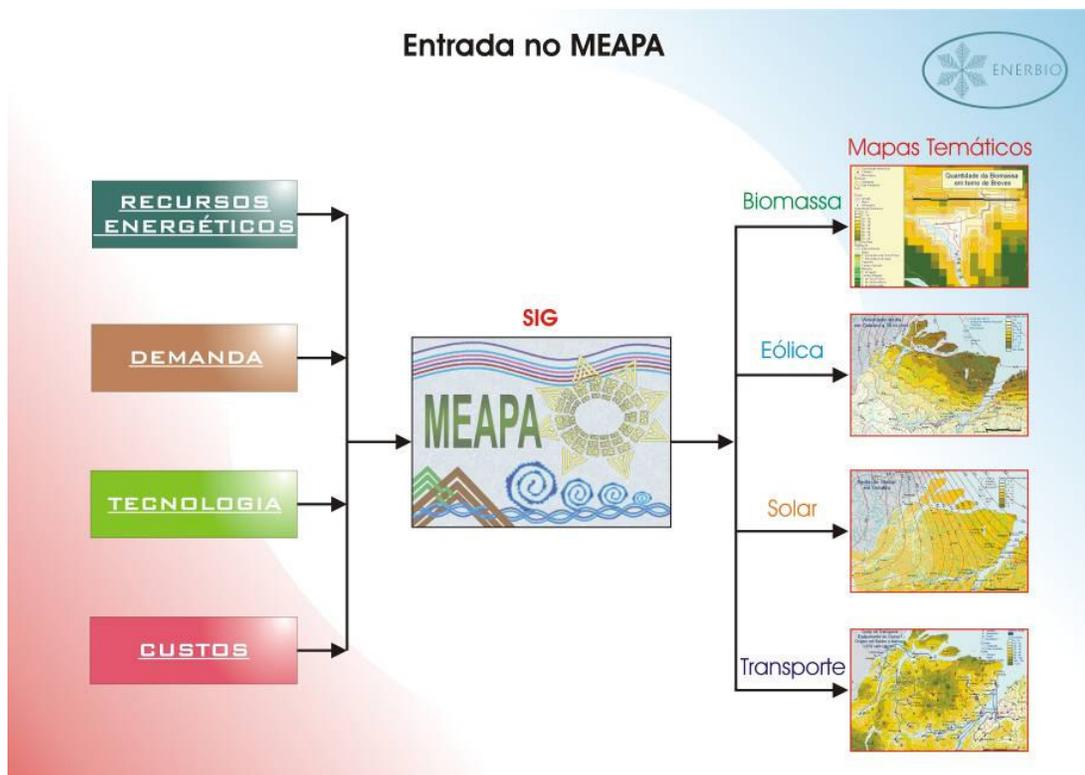


Figura 15 – Esquema da entrada de dados na Aplicação MEAPA

4.2 Metodologia para Inventário de Biomassa Florestal

Tomando-se como base o Relatório da ELETRONORTE (ELETRONORTE, 2001), elaborado pelo Consórcio ENGEVIX-THEMAG para a Eletronorte – Centrais Elétricas do Norte do Brasil S. A, que serviu de base para o Processo de Licenciamento junto a SECTAM –Secretaria Executiva de Ciência e Tecnologia e Meio Ambiente do Pará, quando da elevação do nível de água máximo operacional de reservatório da cota 72m para a cota 74m, foram os principais domínios fitofisionômicos, ocorrentes e identificados na área de influência do lago da Usina Hidrelétrica de Tucuruí, a saber:

- **Tipologia 1 (Falc)** – Floresta aberta com cipó, latifoliada, relevo acidentado.
- **Tipologia 2 (Fdpm)** – Florestas Mistas em planícies aluvionais periodicamente inundadas.
- **Tipologia 3 (Fdoe)** - Floresta submontana, (com menos de 60m de altura), com dossel uniforme, relevo ondulado.
- **Tipologia 4 (Fdou+Famc)** - Floresta submontana, (com menos de 600m de altura), relevo dissecado, fortemente ondulado, com dossel uniforme. Subordinadamente,

Floresta ombrófila aberta mista, relevo acidentado. OBS: Área com forte antropização proporcionando alto grau de ocorrência de babaçu.

- **Tipologia 5 (Fdou+Famc)** - Floresta submontana, (com menos de 60m de altura), relevo dissecado, fortemente ondulado, com dossel uniforme. Subordinadamente, Floresta ombrófila aberta mista, relevo acidentado.
- **Tipologia 6 (Fdae+Fala+Fama)** – Floresta aluvial com presença de árvores emergentes. Subordinadamente, Floresta ombrófila aberta com cipó, latifoliada, relevo aplainado. Subordinadamente, Floresta ombrófila aberta mista, relevo aplainado.
- **Tipologia 7 (Fdoe)** - Floresta submontana, (com menos de 60m de altura), relevo dissecado, fortemente ondulado, com dossel uniforme.

As áreas das tipologias selecionadas foram localizadas e identificadas no mapa de vegetação elaborado na escala de 1:600.000 a partir das Cartas de Vegetação do Radambrasil (BRASIL, 1974), pelo Consórcio ENGEVIX-THEMAG, no ano 2001, as quais foram inventariadas, através de 14 unidades de amostras de 10 m de largura por 200 m de comprimento, em cada tipologia selecionada, totalizando assim 98 unidades de amostra, onde foram identificadas as espécies, seu diâmetro à altura do peito e a altura do fuste das árvores, a partir de 15 cm de diâmetro.

Para a determinação do volume real foi utilizado o procedimento de Smalian (CAMPOS et al, 1985), medindo-se os diâmetros ao longo dos fustes em seções contínuas de 2 m, através das equações 31, 32 e 33:

$$V = \sum_{i=1}^n V_i \quad \text{Eq. 33}$$

sendo

$$V_i = \frac{g_i + g_{i+1}}{2} \times L_i \quad \text{Eq. 34}$$

$$g_i = \frac{1}{4\pi} \times \left(\frac{C_i}{100} \right)^2 \quad \text{Eq. 35}$$

e por último L_i é igual ao comprimento da seção em metros, sendo C_i a circunferência em centímetros nas diferentes seções ao longo do fuste, conforme ilustrado na Figura 16.

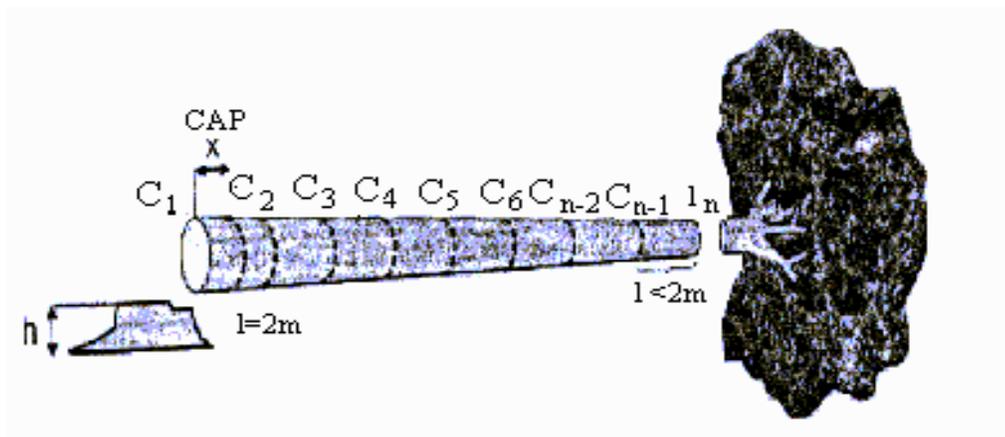


Figura 16 - Esquema da coleta de dados para o cálculo do volume real, pela metodologia de Smalian (CAMPOS et al, 1985).

O cálculo do volume real foi executado no software Microsoft Excel®, a partir das informações referentes à altura e suas respectivas circunferências, de C_1 a C_n , classificando a altura da maior para menor, visando conhecer o máximo de seções empregadas na equação 34. Foi calculado o número de seções, o comprimento da última seção (L_n) e suas respectivas áreas transversais (g_i), para se incluir na fórmula genérica do volume real,

$$V = g_1 + g_{n-1} + 2 \times (g_2 + g_3 + \dots + g_{n-2}) + ((g_{n-1} + g_n) / 2) \times L_n \text{ Eq. 36}$$

a fim de se acelerar o processo de cálculo do volume real de cada árvore-amostra.

Após a coleta de dados de campo, e a obtenção do volume real das 110 árvores-amostras levantadas, foram testados vários modelos de regressão como tentativa de obtenção de equações de volume que pudessem ser utilizadas para a estimativa do volume do fuste, da copa e total das árvores inventariadas. Por outro lado, também foi determinado o fator de forma, isto é um fator de ajuste no cálculo dos volumes, uma vez que os fustes das árvores são, em geral, cônicos e não cilíndricos, como supõem as equações de volume. Esse fator de forma, variável em função da espécie estudada, foi calculado para todas as espécies da área de estudo.

4.2.1. Critérios de seleção dos modelos de regressão

Foram ajustados os oito modelos matemáticos citados na Tabela 2, os quais foram submetidos a critérios estatísticos de seleção. Além desses critérios estatísticos, também

foram considerados os critérios de praticidade de uso das equações e o custo da obtenção dos dados de campo.

Nas equações da Tabela 2, b_0 , b_1 e b_2 são parâmetros de ajuste, V é o volume, d é o diâmetro medido, h é a altura do fuste e DAP é o diâmetro medido à altura do peito.

Tabela 2 - Modelos pré-selecionados para serem ajustados para determinação de equações de volume para a floresta (CAMPOS et al., 1985).

Variável independente	Autor	Equações
<i>DAP</i>	Kopezky-Gehhardt	$V = b_0 + b_1 d^2$
	Hohenalldl-Krenn	$V = b_0 + b_1 d + b_2 d^2$
	Berkhout (B. Husch [1963])	$V = b_0 d^{b_1}$ ($V = b_0 + b_1 d$) $\log V = b_0 + b_1 \log d$
	Brenac	$\log V = b_0 + b_1 \log d + b_2 (1/d)$
<i>DAP /H</i>	(S. H. Spurr [1952])	$V = b_0 + b_1 d^2 h$
	Schumacher-Hall	$\log V = b_0 + b_1 \log d + b_2 \log h$
	(S. H. Spurr [1952])	$\log V = b_0 + b_1 \log(d^2 h)$

4.3.2.1. Análise de Dados

Os volumes foram calculados na planilha do software EXCEL, e juntamente com as variáveis diâmetro (d) e altura (h), foi gerada a matriz com todas as variáveis necessárias para serem utilizadas posteriormente no software de regressão BIOESTAT (AYRES et al., 2003). Para isso, foi montada tabela de variáveis do Grupo-1 (simples entrada) e Grupo-2 (dupla entrada), no sentido de facilitar a análise dos dados.

4.3.2.2. Comparação do Volume Real com os estimados pelas equações de regressão selecionadas e ou pelas equações utilizando o Fator de Forma.

Os volumes estimados pelas equações de regressão selecionada, tanto a de simples entrada, $V=f(DAP)$, quanto a de dupla entrada, $V=f(DAP, H)$, foram comparados com os volumes reais calculados pela metodologia de Smalian (CAMPOS et al, 1985), através do cálculo da probabilidade p , do teste qui-quadrado χ^2 .

4.3.2.2.1. Fator de Forma

Árvores que apresentam os mesmos valores de diâmetro e de altura não necessariamente, apresentam o mesmo valor para o volume, devido as diferentes formas dos

fustes das árvores. As formas dos fustes das árvores sempre apresentam variações em função da diminuição do diâmetro da árvore, no sentido da base para o ápice.

A literatura que trata sobre mensuração florestal, denomina essa diminuição de “*taper ou afilamento do fuste*”, proporcionando a variação no volume da árvore em relação ao volume do cilindro, variando em função da espécie, idade, posição sociológica e condições de sítio.

Fator de Forma (*ff*) é a razão entre o volume real da árvore e o volume de um cilindro de altura igual à altura da árvore e com diâmetro igual ao DAP, e esse Fator de Forma, assim calculado, é denominado de *Fator de Forma Normal*. Assim, temos:

$$ff_{1,5} = \frac{V_{arv.}}{V_{cilind.}} \quad \text{Eq. 37}$$

$V_{arv.}$ = Volume real da árvore obtido pelo método de Smalian (CAMPOS et al, 1985)

$V_{cilind.} = g.H$, sendo $g = \frac{\pi.dap^2}{4}$ e $H =$ altura real da árvore

Deste modo, foram calculados os fatores de forma para todas as árvores das espécies amostradas e, para as mais frequentes entre as árvores-amostras medidas no campo, determinando o fator de forma médio para a área estudada.

4.3.2.2.2. Determinação da Densidade Básica da Madeira

A metodologia adotada para a obtenção da densidade básica, apresentou a seguinte rotina:

Os corpos de prova foram preparados, selecionando-se 15 (quinze) pedaços de madeira. Os pesos desses corpos de prova foram determinados por uma balança de precisão 0,01g, e seus volumes foram determinados com base no princípio de Arquimedes.

A densidade foi determinada com base na Norma NBR11941 da Associação Brasileira de Normas Técnicas – ABNT (ABNT, 2003) que trata da densidade da madeira, calculada através da Equação 38.

$$\rho = \frac{Po}{V_{(sat)}} \quad \text{Eq. 38}$$

Considerando que,

- ρ - densidade básica (g/cm^3).
- P_o - peso do corpo de prova absolutamente seco (g).
- $V_{(\text{sat})}$ - volume do corpo de prova saturado (cm^3).

4.3.2.2.3. Determinação do Poder Calorífico

Poder calorífico de um combustível é a quantidade de calorias liberadas na combustão completa de uma unidade de massa desse combustível.

Para encontrar o Poder Calorífico Superior (PCS) foi utilizada a bomba calorimétrica adiabática, mostrada na Figura 17, pertencente ao Laboratório de Tecnologia de Produtos Florestais (LTPF, UFRA), pelo método de Berthelot, que consiste na combustão do material em um ambiente fechado, na presença de oxigênio e sob pressão, de acordo com a norma D250/50 da ASTM – (American Society for Testing and Materials) (ASTM, 2002). Foram utilizadas cinco amostras de cada tratamento, devidamente seco. O Poder Calorífico Inferior (PCI) é aquele calculado a partir do PCS considerando o teor de umidade a que se encontra o combustível. O PCI é aquele que retrata melhor a qualidade do combustível, visto que será padrão àquele combustível, independentemente do teor de umidade de equilíbrio da região. Já que no PCS está contido o calor necessário para evaporar a água contida no material, que varia em função das condições em que está exposta.



Figura 17 – Fotografia da bomba calorimétrica usada para determinação do poder calorífico.

$$\text{PCI} = ((\text{PCS} - 25,11 \times H)) / (100 + H) \times 100$$

Considerando:

PCI = Poder calorífico inferior

H= umidade do material base peso seco

4.3 Metodologia para caracterização das áreas inventariadas das principais tipologias ocorrentes na área do entorno do reservatório da UHE-Tucuruí.

A caracterização da tipologia das áreas inventariadas no presente levantamento, se deu primeiramente, com base na classificação tipológica proposta pelo Projeto Radambrasil, em 1974, conforme apresentado pelo Relatório (ELETRONORTE, 2001), elaborado pelo Consórcio ENGEVIX-THEMAG para a Eletronorte – Centrais Elétricas do Norte do Brasil S.A., e em segundo lugar com base nas informações de campo, observadas durante a realização do Inventário Florestal como, também, pelos dados obtidos através da análise das parcelas inventariadas, tais como: riqueza florística, frequência de ocorrência de árvores por hectare, volume por hectare, peso em toneladas por hectare e área basal das áreas das diferentes tipologias.

4.3.1. Metodologia para a classificação das áreas antropizadas

A implantação da Usina Hidrelétrica de Tucuruí formou um lago de aproximadamente 170 km de comprimento e, inundou uma área de 2.875 km² formando cerca de 1.600 ilhas inundáveis, das quais 600 são habitadas por pescadores e pequenos lavradores. A formação do lago causou modificações consideráveis de ordem fisiográficas e socioeconômicas na região, tornando-a uma das mais degradadas da Amazônia brasileira. Só no entorno do lago, estima-se que cerca de 50 a 60% das áreas encontra-se com alto grau de antropismo, áreas essas que apesar de possuírem um pequeno estoque de biomassa e, principalmente, de biomassa de palmeiras, mas devido suas grandes extensões é fundamental que se tenha de não apenas classificá-las, mas principalmente estimar o potencial de biomassa existente em cada tipo de classificação.

No intuito de realizar a classificação acima mencionada, foram utilizados os seguintes equipamentos: Máquina fotográfica digital marca Sony modelo DSC-P31, resolução de 3.2Mpixel, zoom 3x digital; GPS marca Garmin modelo 12XL, precisão máxima 3m; embarcação motorizada vulgarmente denominada “voadeira”.

O método utilizado para classificação foi baseado em observação *in loco*. A equipe que realizava a atividade deslocava-se até 20 m a 25 m de distância da margem, sendo

possível focar a área com a precisão desejada e utilizava-se dos equipamentos para capturar imagem e determinar a posição geográfica da área vistoriada, conforme ilustração (Figura 18).

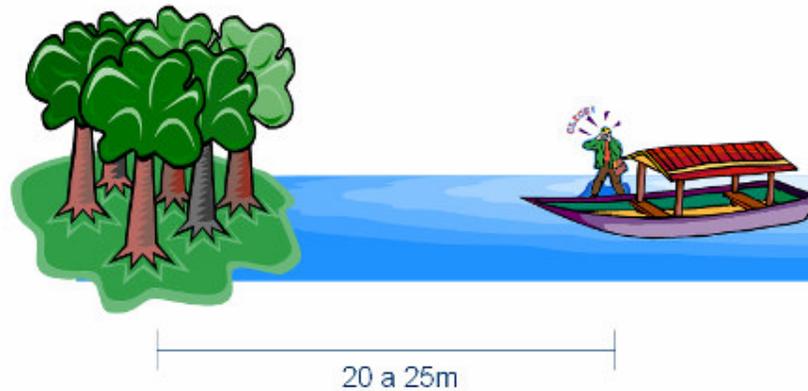


Figura 18 – Esquema do método de aquisição das imagens das áreas antropizadas

4.3.2. Definição das tipologias encontradas

Através do método mencionado, as áreas antropizadas foram descritas nas seguintes classes:

1- Terra Nua:

- 1.1- Terra nua, gradeada pronta para o plantio
- 1.2- Terra nua queimada

2- Pasto Limpo:

- 2.1- Capim plantado, sem ocorrência de árvores, arbustos e palmeiras;
- 2.2- Capim plantado, com ocorrência de árvores, arbustos e/ou palmeiras;
- 2.3- Capim plantado, com ocorrência esparsas de árvores, arbustos e/ou palmeiras;
- 2.4- Capim plantado, com ocorrência frequente de árvores, arbustos e/ou palmeiras.

3- Pasto Sujo:

- 3.1- Pasto sujo, com características de início de uma capoeirinha, porém sem ocorrência de árvores, arbustos e/ou palmeiras;
- 3.2- Pasto sujo, com características de início de uma capoeirinha, porém rara ocorrência de árvores, arbustos e/ou palmeiras;
- 3.3- Pasto sujo, com características de início de uma capoeirinha, porém com ocorrência esparsa de árvores;

3.4- Pasto sujo, com características de início de uma capoeirinha, porém com ocorrência freqüente de árvores, arbustos e/ou palmeiras.

4- Capoeirinha:

4.1- Capoeirinha estabelecida, sem ocorrência de árvores, arbustos e palmeiras;

4.2- Capoeirinha estabelecida, com ocorrência de árvores, arbustos e/ou palmeiras;

4.3- Capoeirinha estabelecida, com ocorrência esparsas de árvores, arbustos e/ou palmeiras;

4.4- Capoeirinha estabelecida, com ocorrência freqüente de árvores, arbustos e/ou palmeiras.

5- Área Agrícola:

5.1- Pimenta do Reino;

5.2- Açaí;

5.3- Mandioca;

5.4- Banana.

6- Área recentemente inundada:

6.1- Área recentemente inundada pela elevação da cota do reservatório de 72 para 74 metros.

4.4 Metodologia para Tratamento da Imagem de Satélite.

Foram usadas imagens do satélite LANDSAT, da órbita 224, ponto 63, que cobrem a região do Lago de Tucuruí, nas bandas 1, 2 3 e 4. Essas imagens possuem resolução espacial de 30 m por pixel.

De posse da imagem e com as coordenadas dos pontos de inventário, foi usado o software SPRING para se obter os valores de refletância das áreas inventariadas. As planilhas de dados são formadas pelas colunas contendo as coordenadas da região, os valores de refletância (DN) das bandas 1, 2, 3 e 4, o valor de biomassa encontrado na amostra e o NDVI (*Normalized Difference Vegetation Index*), calculado a partir das bandas 3 e 4, segundo a equação

$$NDVI = \frac{IVP - VER}{IVP + VER} \quad \text{Eq. 39}$$

onde

IVP = DN da banda de infravermelho próximo

VER = DN da banda do vermelho.

Essa planilha, então, foi usada como entrada para o treinamento e validação dos resultados apresentados pela rede neural RBF.

4.4.1. Softwares utilizados.

4.4.1.1. SPRING, EXCEL, MATLAB e ARCVIEW.

O SPRING (CAMARA et al., 1996) é um SIG (Sistema de Informações Geográficas) distribuído livremente pelo INPE (Instituto Nacional de Pesquisa Espacial), com funções de processamento de imagens, análise espacial, modelagem numérica de terreno e consulta a bancos de dados espaciais.

Sua principal característica é a de fornecer um ambiente unificado de Geoprocessamento e Sensoriamento Remoto para aplicações urbanas e ambientais. Assim, ele facilita a ligação de procedimentos que envolvem simultaneamente o uso de imagens de sensoriamento remoto, (imagens de satélite, por exemplo) como as aplicações de SIG propriamente ditas.

O EXCEL é conhecido programa da Microsoft, especializado na manipulação e processamento de dados tabulares em forma de planilha.

O MATLAB (MATrix LABORatory), da Mathworks, é programa matemático de computação científica, de largo uso na comunidade de engenharia. Possui uma linguagem de programação com várias funções matemáticas, principalmente aquelas ligadas à matemática numérica. Também possui certos pacotes de software (toolbox) especializados em uma determinada área de aplicação. No presente caso, foi usado o pacote de redes neurais para definir os objetos para as redes de Kohonen e RBF (DEMUTH e BEALE, 2002).

O ARCVIEW (ORMSBY, 1999), da ESRI, é também um SIG (Sistema de Informações Geográficas), largamente usado para desenvolvimento de aplicações na área. Caracteriza-se por possuir uma linguagem de desenvolvimento, o *AVENUE* (ORMSBY, 1999) e utiliza tanto dados no formato vetorial (mapas) como dados no formato matricial (imagens).

4.4.2. Sensoriamento Remoto e processamento da imagem.

Softwares diferentes foram usados em cada etapa do trabalho.

Inicialmente, para identificar os valores de refletância nas imagens de satélite, foi usado o software SPRING, disponível no site do INPE (Instituto Nacional de Pesquisa Espacial). Uma vez carregado o SPRING, abria-se a imagem do satélite e eram fornecidas as coordenadas do ponto de inventário. O software mostrava, então, uma matriz de 5 x 5 pontos, com os valores de refletância do ponto pedido e de uma vizinhança de 24 outros pontos. Esses valores eram então anotados em uma planilha do EXCEL.

No EXCEL, foram montadas as planilhas contendo coordenadas do ponto de inventário, os valores de refletância do ponto e de sua vizinhança, obtidos no SPRING, e o volume de biomassa referente àquele ponto, verificado no inventário. Essa informação foi feita para cada uma das 4 bandas usadas da imagem do satélite.

No MATLAB foram codificados os programas que definem e usam as redes neurais usados no processamento e na classificação das imagens de satélite;

4.4.3. *Redes Neurais Artificiais.*

As redes neurais artificiais e o processamento propriamente dito ocorreu no MATLAB (DEMUTH e BEALE, 2002), versão 6. Na linguagem do MATLAB foram escritos os programas de processamento, bem como foram feitas as implementações das redes neurais de Kohonen e RBF, mostrada na Figura 19, usadas no trabalho.

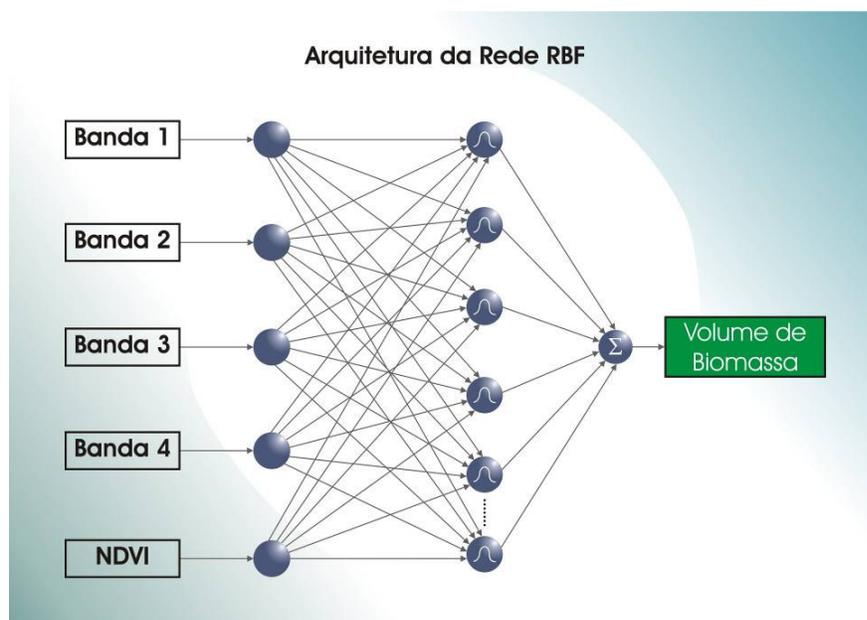


Figura 19 - Arquitetura da rede RBF

4.4.4. *Sistemas de Informações Geográficas (SIG)*

Finalmente, no ARCVIEW, um sistema de informações geográficas, as informações foram integradas, para que os resultados pudessem ser vistos tanto de forma gráfica como pictórica, em forma de mapas codificados, da região de estudo.

Capítulo 5

INVENTÁRIO FLORESTAL DA ÁREA DE ESTUDO

5.1 Caracterização da Área de Estudo.

A área de estudo foi o entorno do Reservatório de Tucuruí, entendendo-se como tal, a região compreendida entre os paralelos 3° 42' S e 4°56'S e os meridianos 49° 20' W e 49° 58' W, abrangendo uma área de 9.633 km², aproximadamente 963.000 há, mostrada na Figura 20, um recorte da imagem do LANDSAT que cobre a região.

A barragem de Tucuruí está situada na região amazônica, nas coordenadas geográficas, latitude 03° 45' S e longitude de 49° 41' W, no baixo Rio Tocantins, a cerca de 300 km em linha reta da cidade de Belém, capital do Estado do Pará.

O eixo principal da bacia do Tocantins-Araguaia pertence ao estuário do rio Amazonas, possuindo em torno de 2.500 km. A vazão média anual da bacia atinge os 10.950 m³/s, com drenagem aproximada de 700.000 km², correspondendo a cerca de 7% do território nacional. O índice pluviométrico está compreendido entre 1.400 mm a 2.400 mm, com a umidade relativa média em torno de 75 a 85%, existindo um período de estiagem entre os meses de setembro e outubro e o período das cheias entre fevereiro e abril. As temperaturas encontram-se nas faixas de 22°C (junho) e 38°C (agosto e setembro).

Na área da represa os solos são ácidos e pobres e o relevo é suave, apresentando desnível de 11 metros entre a soleira da barragem e o nível do mar.

A vegetação predominante é o cerrado, passando a constituir ao Norte da região de Itaguatins (Goiás), a Floresta Mesófila, em uma faixa de transição entre a Floresta Amazônica.

A fauna na região do baixo Tocantins é considerada uma das mais ricas e diversificadas do mundo, com *habitat* proveniente dos ambientes da Amazônia e do Cerrado.

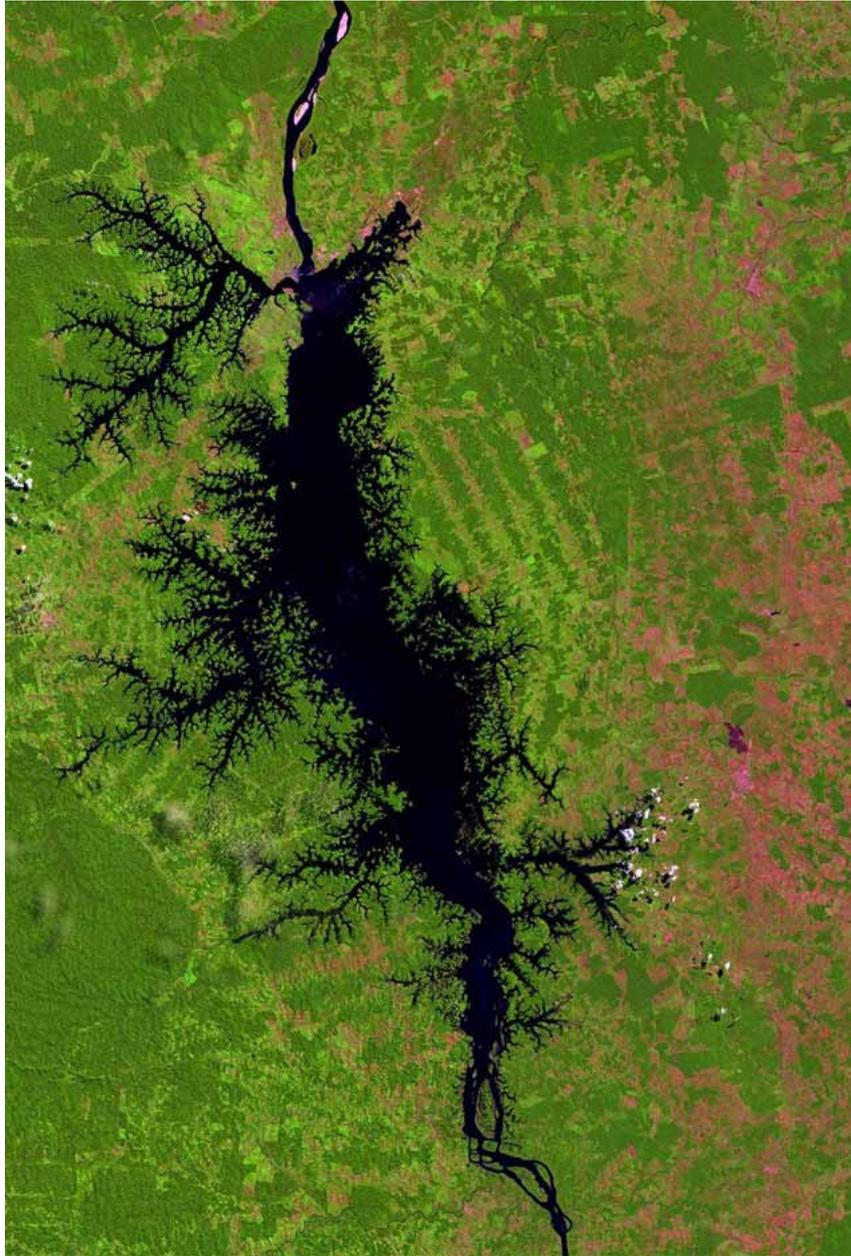


Figura 20 - Área de estudo: Entorno do Reservatório de Tucuruí. Área situada entre os paralelos 3° 42'S e 4° 56'S e os meridianos 49° 20'W e 49° 58'W

Tucuruí supre hoje o mercado de energia elétrica da região de Belém, pelo sudeste do Estado do Pará, Estado do Maranhão e norte de Goiás, bem como outros estados da região Nordeste do Brasil interligados com a CHESF e ainda, complementarmente, as regiões

Sudeste e Sul do país através da interligação com o sistema FURNAS, recentemente posta em operação. Entre os grandes consumidores estão as empresas mineradoras, em especial as produtoras de alumínio e alumina, ALBRÁS e ALUNORTE.

Observando-se esse potencial, verifica-se que a biomassa existente na área pode ser explorada de acordo com o Mecanismo de Desenvolvimento Limpo (MDL). Segundo Míguez (2008), entre as ações propostas pelo Protocolo de Quioto, o Mecanismo de Desenvolvimento Limpo (MDL) é o mecanismo que mais interessa ao Brasil, pois permitirá a certificação de projetos de redução de emissões de CO₂ e a posterior venda de certificados para serem utilizados pelos países desenvolvidos como modo suplementar para cumprirem suas metas. O MDL é uma oportunidade para as companhias brasileiras desenvolverem projetos de redução de emissões, principalmente a partir do uso de energias renováveis e de aumento de eficiência energética.

O governo brasileiro tendo aprovado e ratificado o Protocolo de Quioto propôs a adoção de crescentes parcelas de energia renovável na matriz energética brasileira. Para isso criou mecanismos de incentivo à adoção de energia renovável pelas concessionárias especialmente a Lei 10.438, de 26 de abril de 2002, que criou o Proinfa, o qual, entre outros objetivos, visa à expansão da oferta de energia renovável por meio da concessão de um incentivo financeiro com piso de 80% da tarifa média nacional de fornecimento ao consumidor final. Esse fundo também incentivará a adoção de sistemas a energia renovável, entre eles a biomassa.

Na região Amazônica os recursos de biomassa encontram-se entre os mais altos do mundo. Por outro lado, o aproveitamento de resíduos de biomassa na geração de energia elétrica contribuirá para a diminuição da demanda de óleo Diesel, a emissão de gases de efeito estufa para a atmosfera, além de gerar mais emprego, fixando assim o homem no campo, contribuindo para a diminuição do êxodo rural. A biomassa aumenta a disponibilidade energética como, também, incrementará a atividade econômica local.

A energia contida na biomassa pode ser explorada de diferentes formas, sendo a mais comum a utilização do calor proveniente da combustão - seja diretamente, seja fabricando vapor para gerar eletricidade. Outros processos, entretanto, podem ter um rendimento maior, como a gaseificação ou a produção de combustíveis líquidos, como o biodiesel.

A utilização da biomassa, como recurso energético, faz parte de uma cadeia produtiva, daí sua importância para a economia local. Uma vez identificado o recurso, deve ser determinado o melhor método para a sua colheita, o seu armazenamento e a sua conversão em energia. O tipo de material necessário para os diferentes carburantes e a sua utilização varia

consideravelmente segundo o destino dos materiais (aquecimento, produção de água quente sanitária, eletricidade ou transportes): que poderá ser uma trituradora de lascas que alimentará a caldeira de água quente; sistema de gaseificação acoplado a uma co-geração de calor e de eletricidade com ligação a uma rede de aquecimento urbano; equipamento de pirólise para produzir carvão de lenha; equipamento para a fermentação de combustíveis líquidos; trituradora e processo químico para fabricar combustíveis líquidos, entre outras.

Além disso, é necessário um estudo atento do ecossistema, antes de lançar um projeto de cultura energética para que se evite a vulnerabilidade às doenças e um risco para a biodiversidade. Convém, igualmente, velar pela preservação da fertilidade dos solos e, se for necessário, evitar retirar os resíduos florestais dos locais cujos solos têm necessidade deste complemento nutritivo.

O transporte do combustível em forma bruta pode causar um problema se as centrais energéticas se encontrarem distantes da fonte de biomassa. Deverá dar-se uma atenção particular às conseqüências hidrológicas induzidas pela captação da água necessária às culturas

O uso de biomassa para fins energéticos também provoca a emissão de gás carbônico, Entretanto, a vantagem em relação aos combustíveis fósseis reside no fato de essas emissões serem, no máximo, equivalentes à quantidade de gás carbônico captado pela biomassa durante o seu crescimento. A cultura e a combustão da biomassa representam, assim, um balanço neutro. Podem, no entanto, existir emissões de gás carbônico relacionadas com as operações de colheita e de transporte. Nota-se, no entanto, que as fontes de bioenergia são menos poluentes do que o carvão ou o petróleo, já que não emitem praticamente nenhum enxofre para a atmosfera.

5.1.1 Coleta de Dados Para Obtenção da Estimativa do Volume.

Paralelamente ao levantamento dos dados das parcelas do Inventário Florestal, foram coletados os dados necessários para o cálculo do volume real das árvores, através do uso da metodologia de Smalian (CAMPOS et al, 1985), para a obtenção de equações de volume, bem como para a determinação do Fator de Forma médio, das árvores da área inventariada. As Figuras 21 e 22 mostram fotografias da equipe se deslocando pelo interior do Reservatório de Tucuruí, em direção aos locais de coleta de dados.



Figura 21 – Fotografia do deslocamento da equipe no interior do lago.



Figura 22 – Fotografia mostrando deslocamento da equipe no interior do lago.

Deste modo, foram derrubadas 100 árvores, devidamente autorizadas pelo IBAMA e, também, foram medidas as 10 árvores que foram quebradas durante o corte das árvores autorizadas, totalizando assim, 110 árvores-amostra medidas.

Os dados foram coletados de árvores-amostra distribuídas em classes diamétricas, por ocasião do corte das árvores. A altura comercial foi tomada no ponto onde houve a destopa (separação do fuste da copa) nas árvores derrubadas. As Figuras 23, 25 e 26 mostram fotografias de pesquisadores da equipe, fazendo diversas medições de circunferência de árvores cortadas e a Figura 24 mostra os discos de madeira já cortados, que serão enviados para processamento no laboratório em Belém.



Figura 23 - Fotografia da equipe de coleta de dados de campo para cubagem do volume real do fuste.



Figura 24 – Fotografia mostrando derruba das árvores - Coleta de dados de campo para cubagem do volume real do fuste.



Figura 25 – Fotografia da equipe fazendo coleta de dados de campo para cubagem do volume real do fuste.



Figura 26 – Fotografia da equipe fazendo registro dos dados de campo para cubagem do volume real de copa.

5.1.2 Coleta de dados Para Densidade Básica e Poder Calorífico

Após as árvores terem sido cortadas, foram retirados discos-amostras de madeira de aproximadamente 5 cm de espessura, na base, no meio e no ápice do fuste. Dos galhos das copas, foram retirados discos-amostra, nos galhos grossos, médios e finos. Esse procedimento foi realizado em todas as 110 árvores-amostras derrubadas.

Os discos-amostras de madeira foram transportados até o Laboratório de Tecnologia de Produtos Florestais (LTDF), da Universidade Federal Rural da Amazônia, em Belém, onde foram determinados a densidade básica e o poder calorífico das amostras de madeira.

5.1.2.1 Dados de Entrada.

A Tabela 3 mostra um exemplo de dados de entrada para a rede neural artificial:

Tabela 3 - Dados de inventário coletado no campo

PARC	B1	B2	B3	B4	NDVI	ALTURA	ÁREA BASAL	VOLUME
101	71	62	50	107	0.363057	13.8	17.704	406.073
102	67	63	52	106	0.341772	8.8	4.173	49.621
103	76	69	57	106	0.300613	11.3	9.022	133.452
104	83	76	69	108	0.220339	10.4	1.581	20.807
105	83	73	65	106	0.239766	12.8	3.43	54.712
106	76	68	60	104	0.268293	11.6	1.427	21.615
107	82	71	64	104	0.238095	13.4	2.702	41.253
108	73	64	54	92	0.260274	13.8	1.732	25.454
109	65	52	42	71	0.256637	12.1	2.078	28.003
110	62	52	44	68	0.214286	11.6	1.402	19.385
111	65	58	46	90	0.323529	9.7	5.375	53.137
112	66	60	46	89	0.318519	12.3	3.26	42.098
113	65	62	51	96	0.306122	10.6	1.874	21.864
114	66	62	49	94	0.314685	12.1	2.47	28.194

PARC indica o número da parcela do inventário florestal realizado

B1 é o valor de refletância da banda 1 encontrado na imagem de satélite, no centro da área.

B2 é o valor de refletância da banda 2 encontrado na imagem de satélite, no centro da área.

B3 é o valor de refletância da banda 3 encontrado na imagem de satélite, no centro da área.

B4 é o valor de refletância da banda 4 encontrado na imagem de satélite, no centro da área.

NDVI é o valor do índice de vegetação normalizado calculado entre as bandas 3 e 4.

ALTURA é o valor médio da altura (em m) das árvores encontradas naquela amostra

AREA BASAL é o valor da área basal (em m²) encontrado naquela amostra de inventário.

VOLUME é o valor do volume total (em m³/há) encontrado naquela amostra do inventário.

Capítulo 6

RESULTADOS E DISCUSSÃO

6.1 Resultados

6.1.1 Volume de Biomassa

A pós os treinamentos da rede RBF, todos os dados de entrada foram introduzidos na rede para que fosse feita a estimativa do volume de biomassa.

As imagens de satélite da área de estudo, formadas pelas quatro bandas, foram então processadas pela rede RBF treinada, obtendo-se estimativas globais para toda a região de interesse. Em seguida, essa imagem, com os valores estimados, foi classificada pela rede de Kohonen, para que regiões com valores semelhantes de volume de biomassa fossem agrupadas.

O resultado dessa interpolação e classificação é mostrado na Figura 27, onde aparecem já classificadas por volume de biomassa, as diversas áreas estimadas. Toda a área de estudo foi submetida ao mesmo processo. Os mapas foram gerados na escala 1:100000, conforme a imagem pequena ao lado direito da figura. As demais partes da área total podem ser vistas no apêndice 2.

6.1.2 Potencial Energético

Considerando-se os valores de volume e de densidade média, obtidos em laboratório, a partir das amostras coletadas em campo, foi obtido o peso do material seco, que foi convertido para kWh e classificando-se a imagem resultante, obteve-se o mapa apresentado na Figura 28, com o potencial energético em kWh para cada área da região de estudo.

Os valores mostrados nesse mapa indicam a quantidade de kWh que poderia ser gerada a partir dessa biomassa, se ela fosse utilizada como combustível primário em um equipamento semelhante a um gaseificador de biomassa. Para conversão em kWh, foram utilizados os dados de rendimento contidos em (QUAAK; KNOEF; STASSEN, 1999).

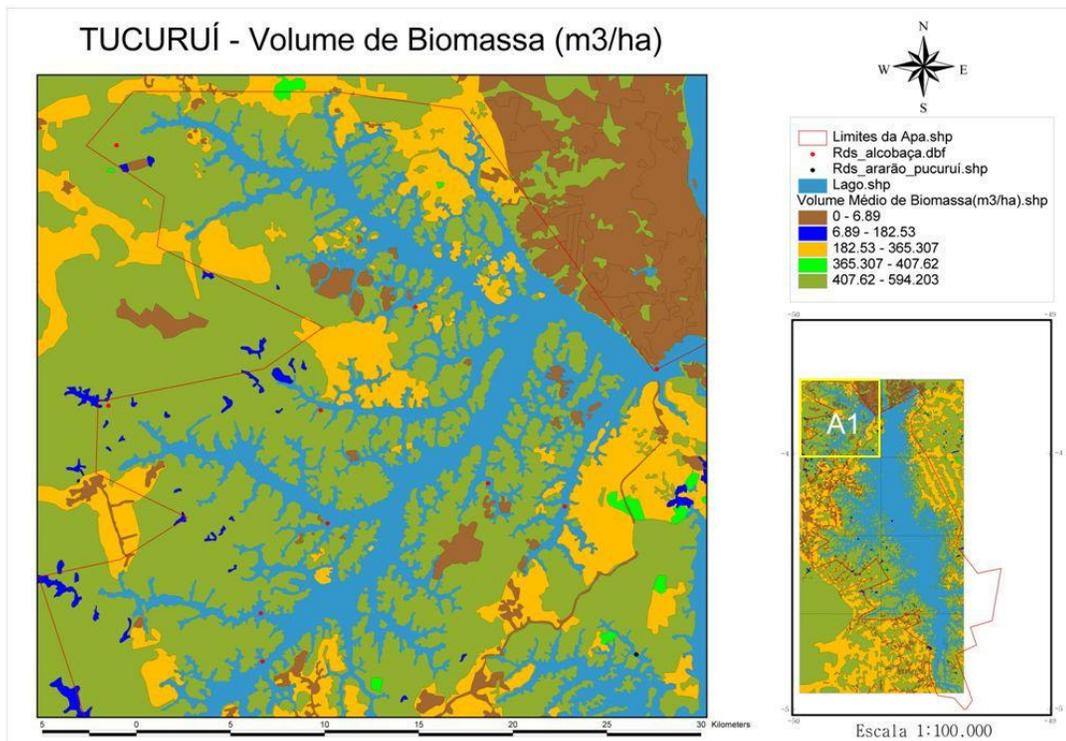


Figura 27 - Volume de biomassa em uma região do reservatório de Tucuruí

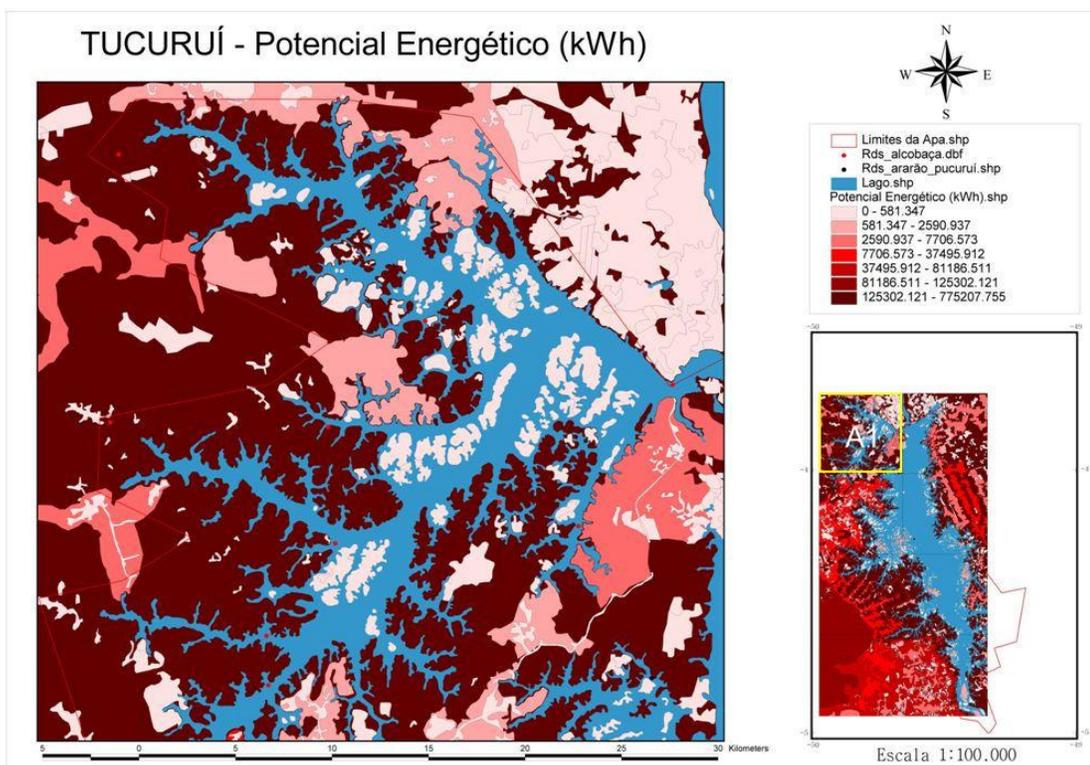


Figura 28 – Potencial energético em uma região do reservatório de Tucuruí

6.2 Discussão.

6.2.1 Discussão global dos resultados.

Indicadores estatísticos clássicos foram usados para aferir a qualidade dos resultados obtidos. São eles o desvio padrão, dado por $s = \sqrt{\frac{(X_i - \bar{X})^2}{N}}$ onde X_i representa cada um dos valores da amostra, \bar{X} é a média aritmética da amostra e N é o número de itens na amostra.

O erro médio quadrático (RMS) dado por $RMS = \sqrt{\frac{(X_i - X_{est})^2}{N}}$, onde X_i representa cada um dos valores da amostra e X_{est} representa cada um dos valores estimados pela rede e N é o número de itens da amostra.

Variância não explicada (VNE), definida por $VNE = RMS^2 / VAR(dados reais)$, onde VAR é a variância dos dados reais.

Coeficiente de correlação R2, dado por $R2 = \sqrt{1 - VNE}$.

Os valores de biomassa estimados pela rede neural com arquitetura RBF produziram os seguintes indicadores estatísticos:

Desvio padrão = 0,0207

Erro médio quadrático (RMS) = 0,0035

Variância não explicada = 0,3227

Coeficiente de correlação (R2) = 0,8230

As Figuras 29 e 30 mostram o desempenho geral do processamento da rede RBF, onde aparecem pontos representando dados reais e pontos com os valores estimados.

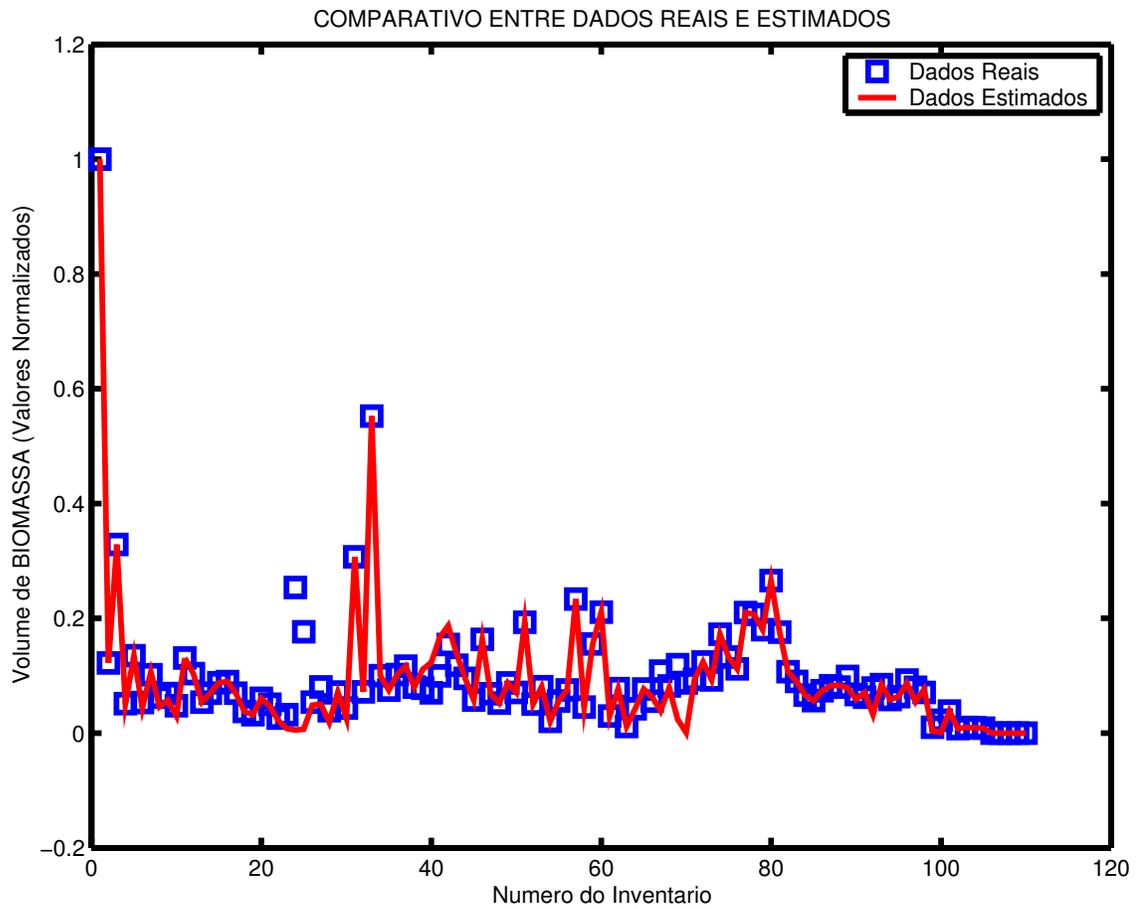


Figura 29 – Comparativo Entre Dados Reais e Estimados

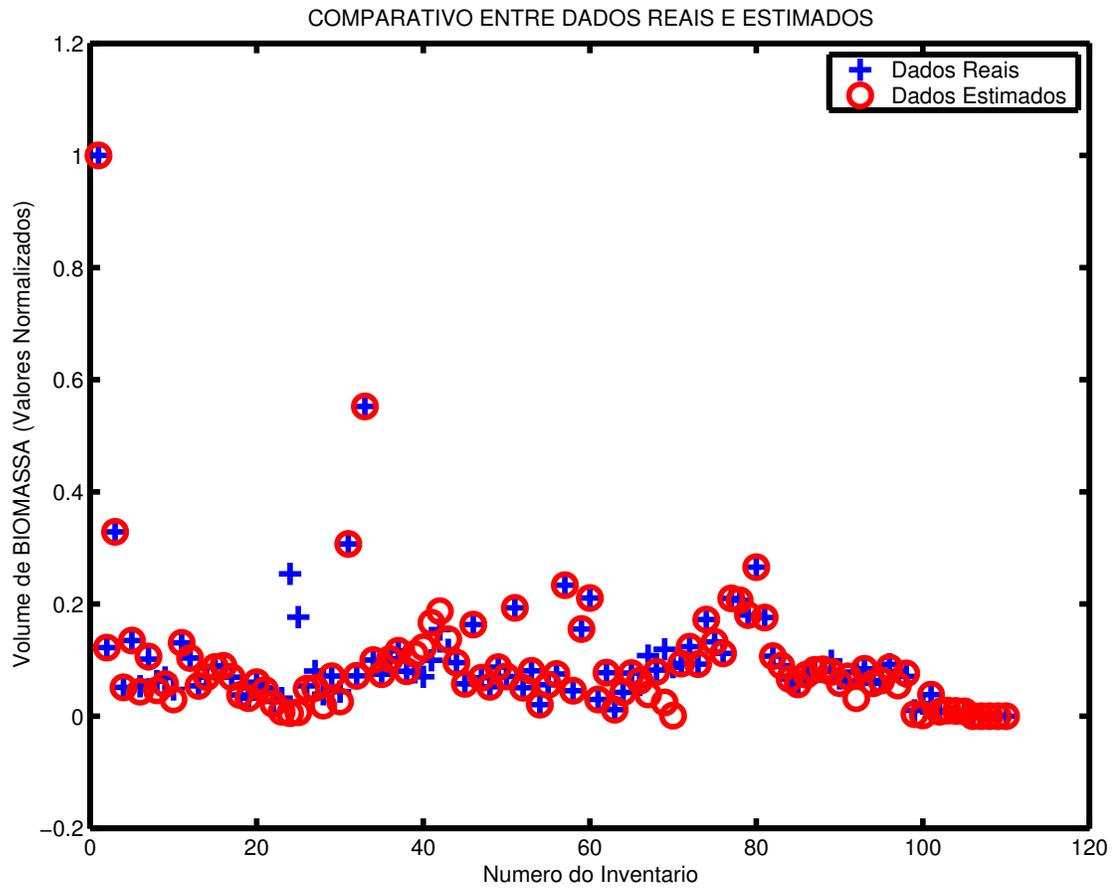


Figura 30 - Comparativo entre dados reais e estimados

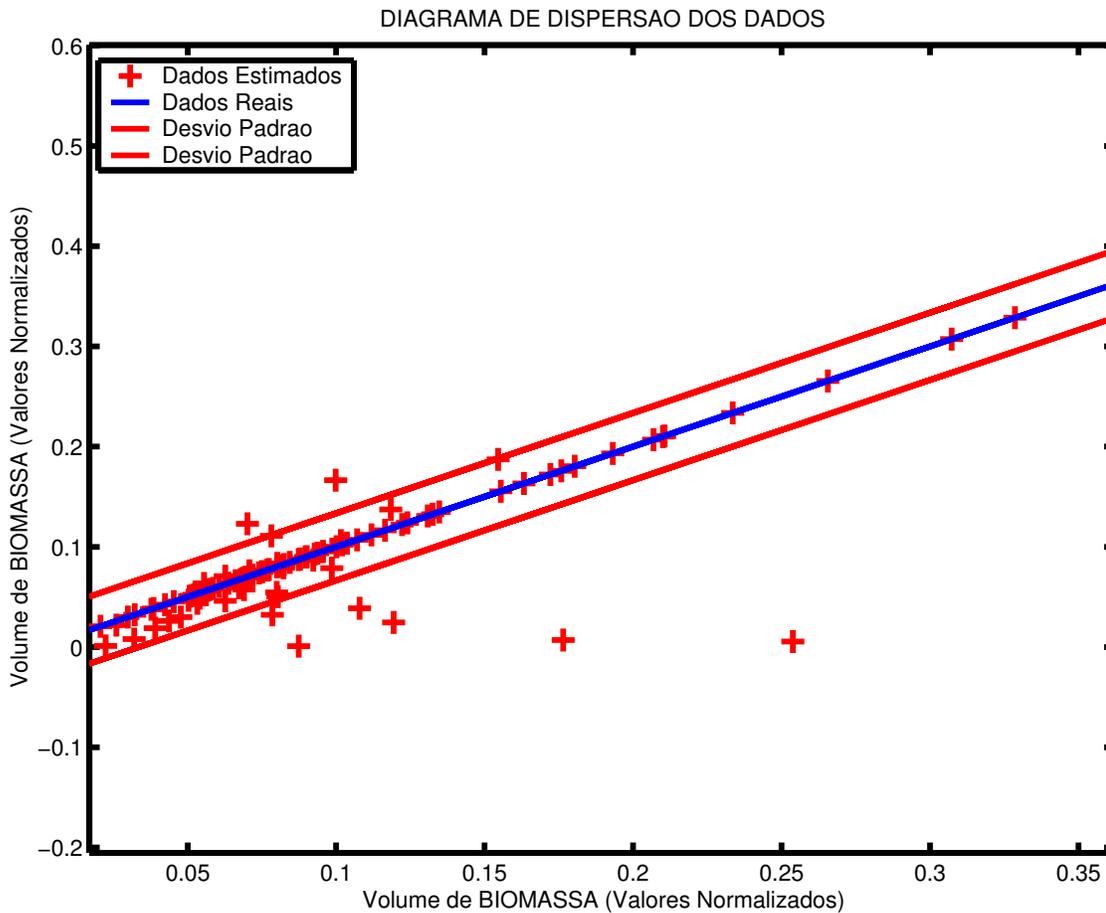


Figura 31 - Diagrama de dispersão dos dados

Na Figura 31, a reta azul mostra a reta de correlação 100%, as cruzes vermelhas os pontos estimados pela rede e as duas retas vermelhas paralelas, estão situadas a uma distância de mais ou menos um desvio padrão.

Foi observada uma forte correlação positiva entre os dados estimados e os dados reais, com menos de 10% (dez por cento) dos dados estimados ficando fora da faixa de mais ou menos um desvio padrão.

O histograma da Figura 32 mostra a distribuição estatística dos dados reais, coletados durante o inventário florestal (A) e os dados estimados pela rede (B), sendo observada uma semelhança muito grande, indicando uma grande margem de acerto.

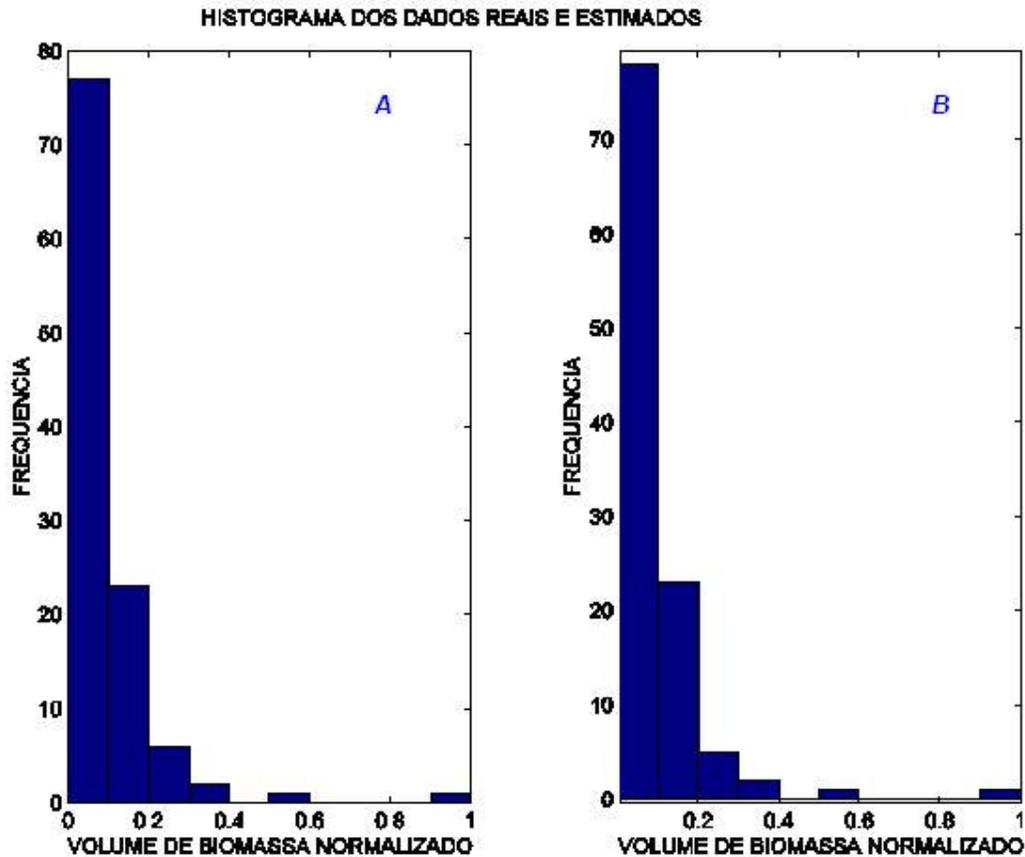


Figura 32 – Histograma dos dados reais (A) e estimados (B)

6.2.2 Variação dos resultados em função da tipologia florística.

É importante questionar se o tipo de vegetação, isto é, a tipologia florística dominante em uma dada área pode afetar o desempenho da rede neural e do subsequente resultado.

No entorno do Reservatório de Tucuruí, foram encontradas sete tipologias florísticas diferentes, segundo documento do Radambrasi (BRASIL, 1974). A seguir, será analisado o resultado da estimativa de biomassa restrito a cada tipologia diferenciada em comparação com o resultado do inventário feito no local.

- **Tipologia 1 (Falc)** – Floresta aberta com cipó, latifoliada, relevo acidentado.
- **Tipologia 2 (Fdpm)** – Florestas Mistas em planícies aluvionais periodicamente inundadas.
- **Tipologia 3 (Fdoe)** - Floresta submontana, (com menos de 60m de altura), com dossel uniforme, relevo ondulado.
- **Tipologia 4 (Fdou+Famc)** - Floresta submontana, (com menos de 60m de altura), relevo dissecado, fortemente ondulado, com dossel uniforme. Subordinadamente,

Floresta ombrófila aberta mista, relevo acidentado. **Tipologia 5 (Fdou+Famc)** - Floresta submontana, (com menos de 60m de altura), relevo dissecado, fortemente ondulado, com dossel uniforme. Subordinadamente, Floresta ombrófila aberta mista, relevo acidentado. OBS: Área com pouca ação antrópica.

- **Tipologia 6 (Fdae+Fala+Fama)** – Floresta aluvial com presença de árvores emergentes. Subordinadamente, Floresta ombrófila aberta com cipó, latifoliada, relevo aplainado. Subordinadamente, Floresta ombrófila aberta mista, relevo aplainado.
- **Tipologia 7 (Fdoe)** - Floresta submontana, (com menos de 60m de altura), relevo dissecado, fortemente ondulado, com dossel uniforme.

A Tabela 4 mostra os valores dos diversos índices estatísticos obtidos em cada um dos inventários por tipologia florística.

Tabela 4 - Índices estatísticos dos inventários por tipologia florística

TIPOLOGIA	Erro Padrão	Erro médio quadrático RMS	Variância não explicada	Coeficiente R2
1	0,0069	0,0049	0,0004	0,9998
2	0,0728	0,5114	0,7022	0,5457
3	0,0235	0,0167	0,0163	0,9918
4	0,0048	0,0032	0,0154	0,9974
5	0,0349	0,0247	0,1529	0,9214
6	0,0000	0,0000	0,0000	1,0000
7	0,0142	0,0099	0,6693	0,5750

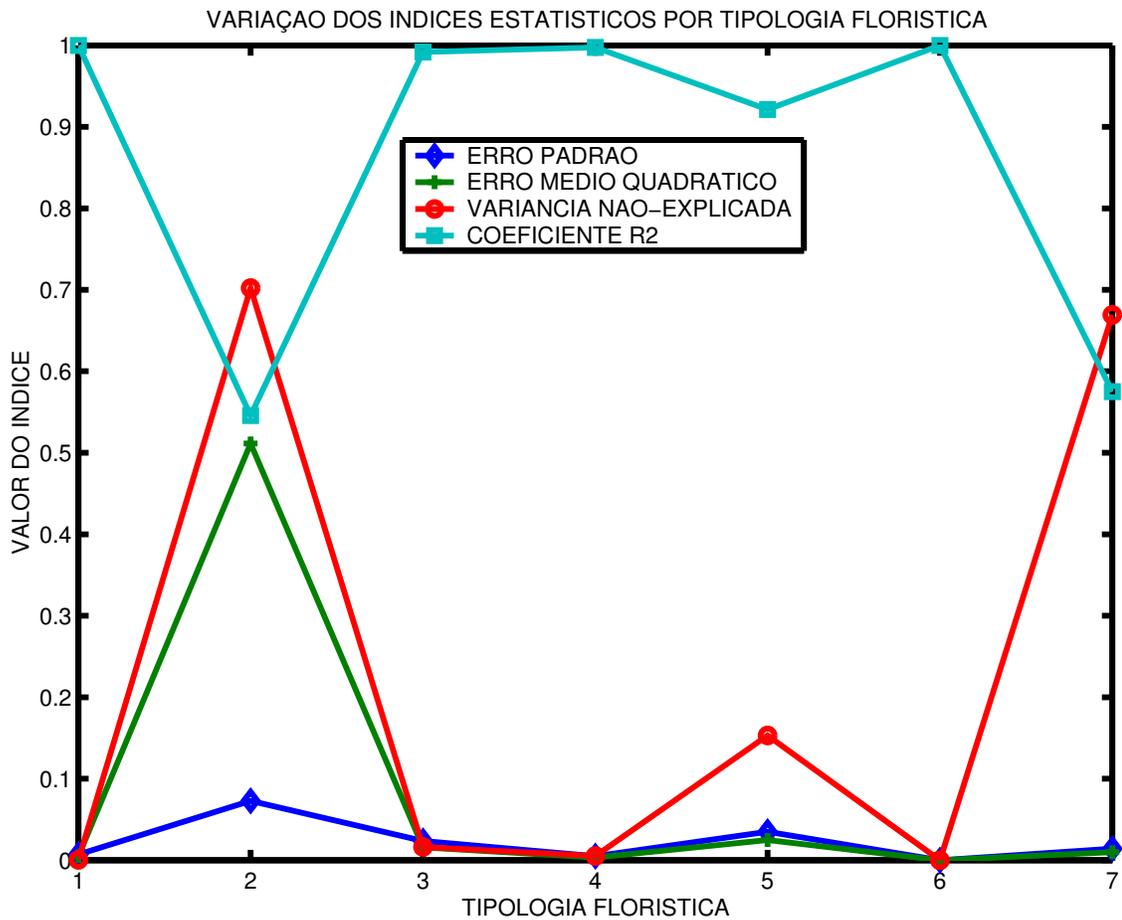


Figura 33 - Variação dos índices por tipologia florística.

Na Figura 33, onde aparece um gráfico comparativo global da variação dos índices estatísticos por tipologia florística, verifica-se que o melhor desempenho ocorreu na tipologia 6, caracterizada por floresta aluvial, com presença de árvores emergentes, subordinadamente, floresta ombrófila aberta, com cipó latifoliada, relevo aplainado, subordinadamente, floresta ombrófila aberta mista, com relevo aplainado.

Já o pior desempenho ocorreu na tipologia 2, caracterizada por floresta mista em planícies aluvionais, periodicamente inundadas e na tipologia 7, definida como floresta submontana (com menos de 60m de altura), relevo dissecado, fortemente ondulado, com dossel uniforme.

6.2.3 Desempenho da rede RBF para aproximação de funções

A escolha pela arquitetura RBF para fazer a aproximação da função que estima o volume de biomassa a partir de dados de uma imagem de satélite foi ditada pelas propriedades matemáticas dessa rede.

Neste trabalho foi feita a aproximação de uma função do tipo

$$\begin{aligned} \phi: R^5 \rightarrow R, (b_1, b_2, b_3, b_4, i) \in R^5 \rightarrow (v \in R) \\ v = \phi(b_1, b_2, b_3, b_4, i) \end{aligned} \quad \text{Eq. 40}$$

Nessa equação, b_1, b_2, b_3, b_4 são os valores dos pixels da imagem do satélite nas bandas 1, 2, 3 e 4 respectivamente, i é o valor do NDVI e v é o volume estimado de biomassa.

Na Figura 34 vemos um exemplo de uma superfície gerada por uma função gaussiana típica.

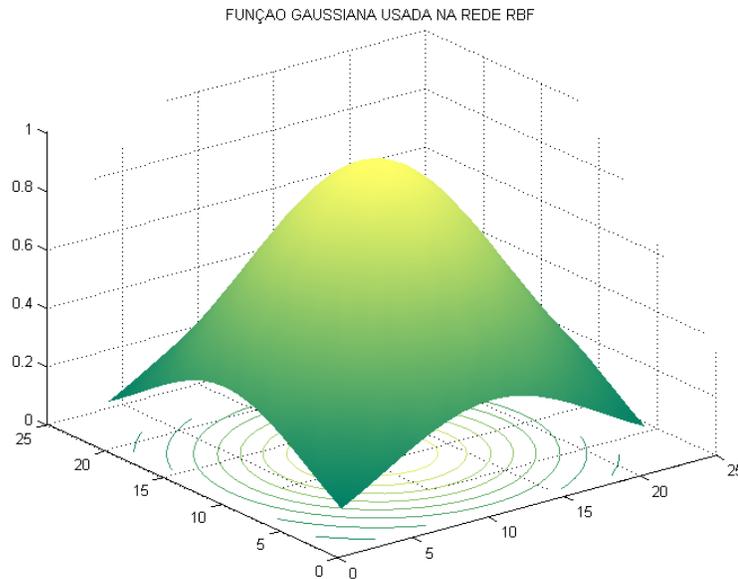


Figura 34 - Superfície gaussiana usada na rede RBF

Conforme (FERRARI e STENGEL, 2005), o treinamento de uma rede neural artificial para uma aproximação suave de uma função contínua em um espaço multidimensional, envolve a otimização numérica do erro existente entre os dados reais, geralmente contidos em uma tabela obtida em medições em campo e os dados estimados pela rede em um dado momento. A partir daí, são obtidos direcionamentos para o treinamento das diversas arquiteturas de redes, bem como para avaliação de suas propriedades aproximativas.

O desempenho ótimo de uma rede RBF, como a usada neste trabalho, depende essencialmente da quantidade e da localização dos centros das diversas funções de base radial (POGGIO e GIROSI, 1992). Esse é um parâmetro crucial para sintonizar o desempenho aproximativo e computacional de uma rede RBF. Em alguns casos, essa escolha foi baseada em tentativa e erro, após análises detalhadas da situação em estudo.

Procedimentos mais sistemáticos podem envolver as seguintes estratégias: (a) escolha aleatória dos centros, a partir dos dados de entrada; (b) estratégias que usam procedimentos não supervisionados para seleção dos centros, (c) uso de métodos supervisionados.

Uma característica desses processos é que não se pode garantir, *a priori*, que a localização e quantidade ótima dos centros serão encontradas por esses procedimentos iterativos. Para sanar essa situação, algumas pesquisas têm feito a proposta de se trabalhar com as redes após um processo de regularização (HAYKIN, 2001).

Para contornar essa dificuldade, neste trabalho, foram usados dois tipos de arquitetura de rede RBF, existentes no Pacote de Redes Neurais do MATLAB (DEMUTH e BEALE, 2002). Duas funções parametrizadas estão disponíveis para se montar a arquitetura de uma rede RBF.

Em uma delas, a *newrb* a rede é construída de forma iterativa. Em cada época de treinamento uma quantidade fixa de neurônios é acrescentada à camada oculta da rede, até que se alcance a aproximação desejada, baseada no valor do erro médio quadrático.

Na outra função, a *newrbe*, a quantidade de neurônios na camada oculta é igual ao número dos vetores de entrada presentes nos dados de treinamento. Nessa opção, após o treinamento, é criada uma rede com erro zero, no que diz respeito aos vetores de treinamento.

Nas duas variantes do modelo RBF, o parâmetro *spread*, presente nas duas funções é que determina a amplitude da base da função, definindo com isso o centro e o número de funções necessárias.

Inicialmente, esperando-se ganhar eficiência, foi usado o modelo iterativo, que vai adicionando neurônios a cada época de treinamento. Foram feitas dezenas de experiências variando tanto o número máximo de neurônios, como a amplitude da base das funções gaussianas. Entretanto, os resultados não foram satisfatórios, pois a discrepância nos dados estimados estava acima dos limites previamente definidos.

Em função disso, foi usado o modelo que utiliza a mesma quantidade de neurônios que os vetores presentes nos dados de entrada. Em termos computacionais, não é a solução mais econômica, mas foi a que se mostrou mais eficiente em termos de precisão dos resultados, mesmo à custa de maior tempo de computação. Como esses dados não precisam ser processados em tempo real, uma diferença de cerca de vinte a trinta minutos em troca de maior precisão, é uma boa troca a ser feita.

Finalmente, foi usado um procedimento alternativo, com a finalidade de se obter uma maior precisão na escolha dos centros das funções gaussianas. Utilizou-se previamente uma rede de Kohonen, nos dados de entrada, com o objetivo de classificar e agrupar os dados em

aglomerados discerníveis nos dados de entradas e, então, usar os centros desses agrupamentos, como centros para as funções gaussianas da rede RBF. Esse procedimento foi o que deu melhores resultados em termos de precisão, trazendo o erro para os valores obtidos nos resultados finais, mostrados acima.

Quanto ao parâmetro *amplitude (spread)*, que especifica o comprimento da base da função gaussiana, após várias tentativas, foi escolhido o valor 0,1, em função da distância entre os diversos pontos de dados de entrada, já com os valores normalizados. Outros valores foram testados, mas esse foi o que deu o melhor resultado, quanto à minimização do erro quadrático. É importante observar a sensibilidade do desempenho da rede ao ajuste desse parâmetro. Durante a fase de treinamento, uma variação de 10% no valor desse parâmetro, era capaz de piorar o desempenho da estimativa da rede em cerca de 50% ou mais.

Uma alternativa proposta na literatura seria aplicar a chamada técnica de regularização na rede RBF. Em essência, essa técnica consiste, segundo (HAYKIN, 2001) em estabilizar a solução por meio de algum funcional linear não-negativo auxiliar que incorpore informação prévia sobre a solução. Considerando-se que os resultados obtidos foram satisfatórios, essa técnica não foi usada neste trabalho.

Durante a fase de testes e treinamentos, foi experimentado, na composição das variáveis de entrada para a estimativa do volume de biomassa, de acordo com recomendações de outros pesquisadores (LU et al, 2002; PANDA, 2004) o uso de várias razões entre as diversas bandas, com a finalidade de se agregar mais informação. Assim, foram testadas as razões entre as bandas 4 e 3 e também entre as bandas 5 e 3. Não foram observadas mudanças significativas nos resultados, além de ter aumentado o tempo de processamento.

Dentre os diversos procedimentos testados com a finalidade de se obter melhores resultados, o que favoreceu foi o de agregar os vetores de entrada em ordem crescente do valor de sua norma euclidiana. Também a normalização dos dados, sempre recomendada na literatura, ajudou nessa tarefa. A normalização usada foi a dada pela Equação 41:

$$\frac{X_i - X_{\min}}{X_{\max} - X_{\min}} \quad \text{Eq. 41}$$

Nessa equação, X_i é o valor a ser normalizado, X_{\max} e X_{\min} são o valor máximo e mínimo, respectivamente, da tabela de dados de campo.

Quanto ao tempo e recursos computacionais usados, foi verificado que no computador do tipo PC, com relógio de 2 GHz e memória RAM de 2048 Mbytes (2 Gbytes) não foi

possível processar a imagem inteira do satélite como era a intenção inicial. O sistema parava com uma mensagem de “Falta de Memória”. Ao ser pesquisado esse problema, foi descoberto ser falta de memória no ambiente interno do MATLAB e não, propriamente, no computador. Como não havia necessidade de se processar toda a imagem, mas somente o que foi definido como o entorno do Reservatório de Tucuruí, uma área de cerca de 1 milhão de hectares, foi feito um recorte da área de estudo a partir da imagem do satélite e esse recorte foi, então, processado sem problemas. Entretanto, se em outra aplicação houver necessidade de processamento de todo um mosaico do satélite LANDSAT, uma área de 170 x 183 km², a recomendação é de se escrever a parte do código que cuida da rede neural em uma linguagem com mais recursos, sendo C++, a candidata mais indicada nessas circunstâncias.

O tempo para processamento da área de estudo foi de cerca de 3 horas e de 2 horas para o passo seguinte de classificação dos resultados na rede de Kohonen. Por conta disso, durante as várias fases de teste, foi feita uma reamostragem da área, usando-se o algoritmo da moda ou o do pixel central, para reduzir o tempo nos testes intermediários. A Figura 35 mostra a evolução da convergência dos pesos da camada de entrada da rede RBF e a Figura 36 mostra a evolução da convergência dos pesos da camada linear dessa rede.

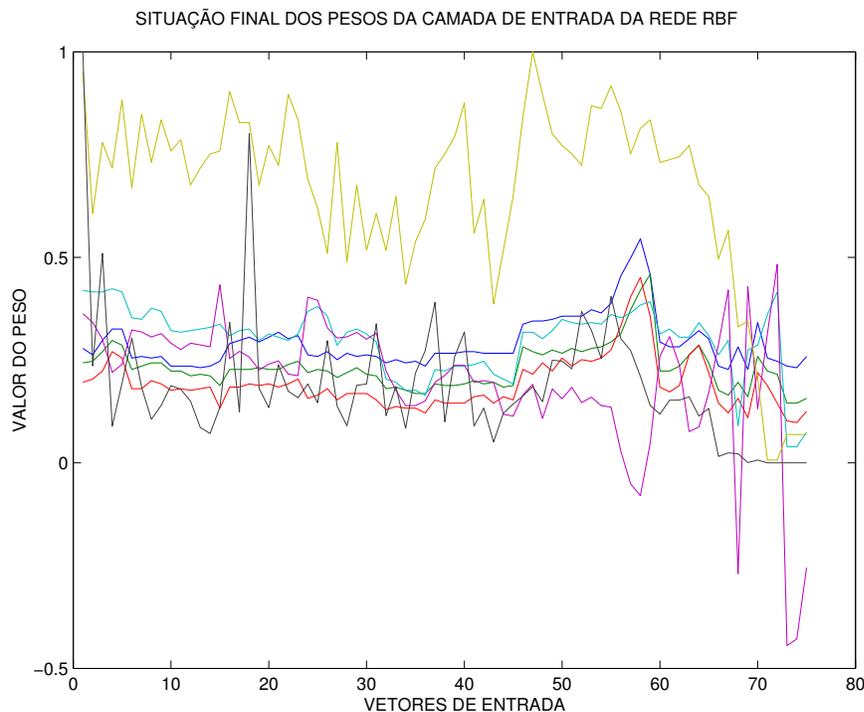


Figura 35 - Situação final dos pesos da camada de entrada da rede RBF

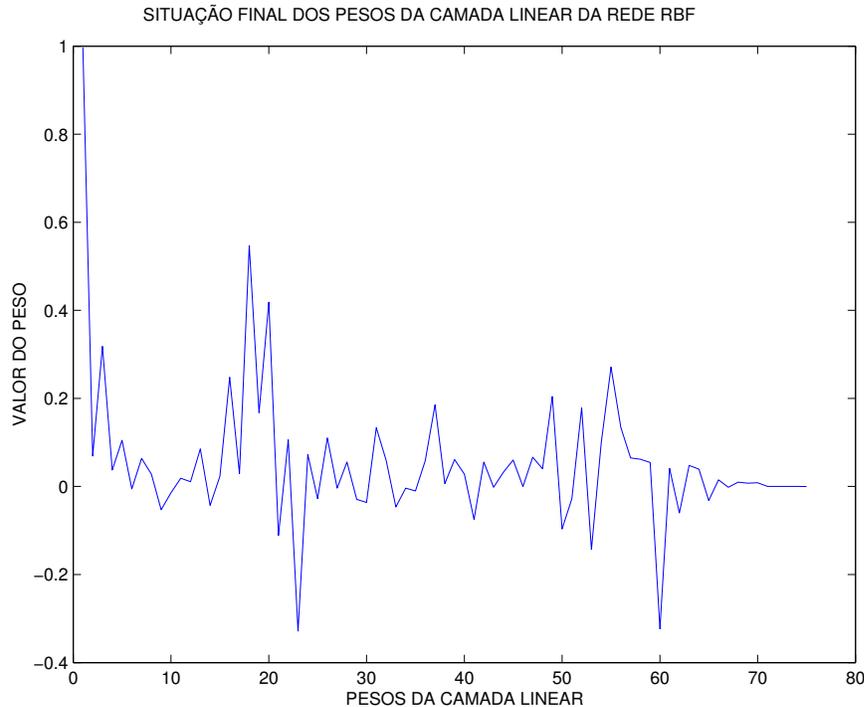


Figura 36 - Situação final dos pesos da camada linear da rede RBF

6.2.4 Desempenho da rede de Kohonen para classificação de imagem.

O problema de classificação de imagens pertence à área de reconhecimento de padrões, uma área que, segundo (BISHOP, 1995) conta para sua solução com os métodos estatísticos entre os mais eficientes, dada a natureza probabilística tanto da informação que está sendo processada, como dos resultados que devem ser apresentados. Entretanto, o recente avanço da teoria e aplicações de redes neurais artificiais no campo do reconhecimento de padrões e classificação de imagens faz com que essas novas técnicas sejam usadas como extensão e amplificação daquelas técnicas estatísticas.

A rede de Kohonen, ou Mapa Auto-Organizável faz parte das redes com treinamento não-supervisionado. Elas extraem informação a partir do próprio conjunto de dados sem necessidade de utilizar amostras dos dados como padrão de comparação.

Em seu treinamento é usado o modelo competitivo, onde o “neurônio vencedor”, isto é, aquele mais próximo do vetor de entrada recebe um reforço para ficar ainda mais próximo, enquanto que os outros ficam sem alteração. Com isso, quando aparecer um outro vetor semelhante aquele, o mesmo neurônio, ou uma vizinhança dele, será novamente ativado.

De forma resumida, pode ser dito que uma rede de Kohonen mapeia um conjunto de dados de um espaço V em um mapa auto-organizável A , de acordo com a equação

$$\phi: V \rightarrow A, (x \in V) \rightarrow (\phi(x) \in A) \quad \text{Eq. 42}$$

Para que o mapa A seja uma representação válida e coerente do espaço vetorial V , é necessário que se tenha a condição seguinte, relacionada ao conjunto de pesos W , que caracteriza o treinamento competitivo das redes de Kohonen:

$$\|W_{\phi(x)} - X\| = \min \|W_r - X\|, r \in A \quad \text{Eq. 43}$$

Por conta dessa característica, a rede de Kohonen tem sido usada com sucesso na tarefa de classificação de imagens, particularmente de imagens de satélite, onde fazem classificação de padrões sem a ajuda de um especialista humano.

Para obtenção dos resultados deste trabalho, duas redes de Kohonen foram usadas. Uma para agrupar os dados de entrada em busca de centros a serem usados na rede RBF que faria a aproximação funcional e a outra, nos resultados, para classificar a imagem de acordo com os valores estimados de volume e de potencial energético da biomassa.

Classificar uma imagem consiste essencialmente, em agrupar pixels com valores parecidos em classes de equivalência, de tal forma que, depois, em um pós-processamento desse resultado, seja possível, por exemplo, pintar em cores diferentes, cada uma dessas classes, exibindo-as visualmente em diferentes tonalidades.

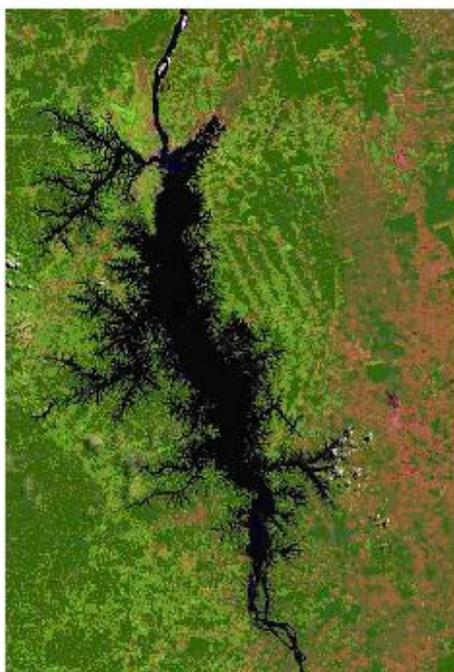
Esse tratamento foi feito com a imagem da região de estudo, o entorno do Reservatório de Tucuruí, com a finalidade de se classificar as áreas de floresta, água, áreas urbanas e áreas antropizadas, mas não urbanas, tais como desmatamentos.

O resultado pode ser visto na Figura 37, onde aparecem lado a lado a imagem original e a imagem classificada. Observa-se que a rede classificou de forma acertada as classes de floresta (em verde), área urbana ou antropizada (em vermelho) e água (em azul), com uma margem de acerto muito próxima de 100%.

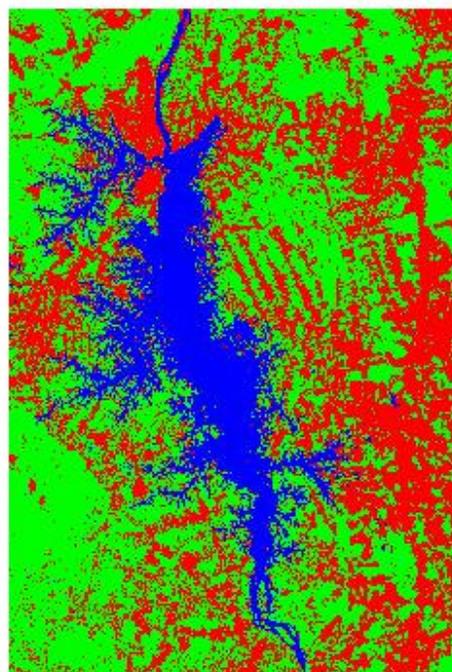
Também é mostrado na Figura 38 um histograma das duas imagens, podendo ser verificado de forma mais fácil, o agrupamento dos pixels da imagem em poucas classes de equivalência.

Como as cores escolhidas para a diferenciação das classes foram o vermelho, o azul e o verde, verifica-se uma concentração no histograma nos pontos extremos do 0 e do 255. Isso se deve ao fato de que no sistema de cores RGB (*Red, Green, Blue*) essas cores são representadas internamente por vetores cujos componentes são os valores 0 e 255. Assim, temos (0,0,255), (0,255,0) e (255,0,0) como os vetores componentes da imagem classificada.

IMAGEM ORIGINAL E IMAGEM CLASSIFICADA



A



B

RESERVATORIO DE TUCURUI

Figura 37 - Imagem original (A) e classificada (B)

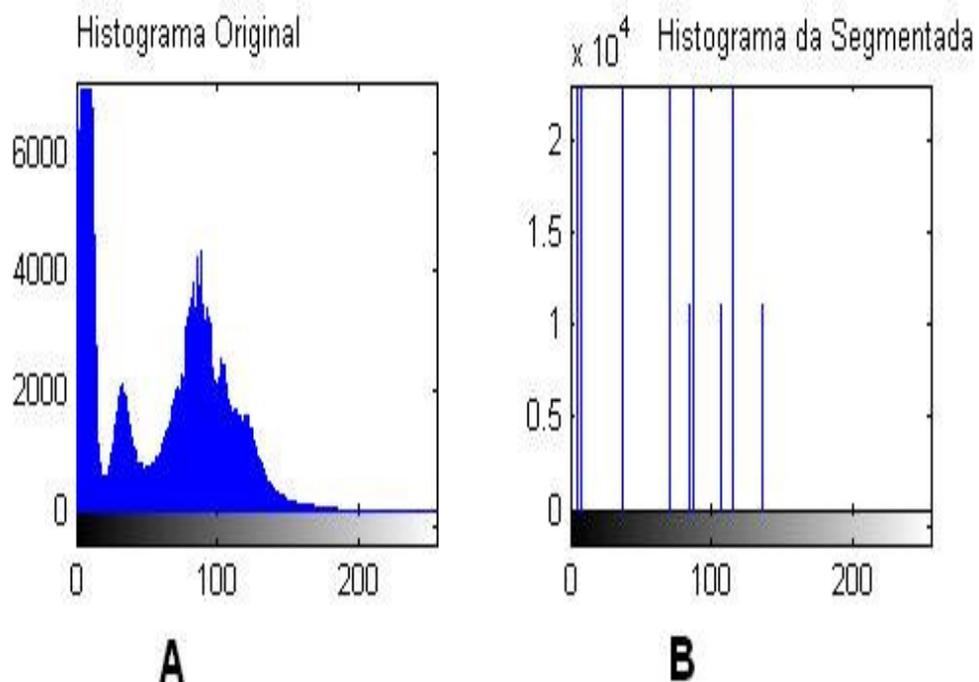


Figura 38 - Histograma da imagem original (A) e classificada (B)

6.2.5 Sistema de Informações Geográficas e Banco de Dados Espaciais.

Como os resultados obtidos neste trabalho possuem uma forte conotação geográfica, tornou-se necessário usar ferramentas de Sistemas de Informações Geográficas (SIG).

Assim, todos os resultados de estimativa de biomassa e estimativa de potencial de energia elétrica possível de ser produzida em um equipamento tal como gaseificador, estão geo-referenciados, isto é, associados a um par de coordenadas em uma imagem de satélite da região de estudo.

Com isso, um resultado adicional ao trabalho, foi a criação de um banco de dados espacial da região, envolvendo dados espaciais e outros, tais como o volume de biomassa e o potencial energético da área. É possível agregar a esse banco de dados informações relevantes ao planejamento energético com energias renováveis, tais como custo de coleta e transporte de biomassa, velocidade e direção de ventos e radiação solar incidente na área, completando assim o quadro de informações necessárias à execução do sistema *MEAPA* na região.

Esse banco de dados pode tanto ser usado para a aplicação primária de planejamento energético, tal como foi pensado inicialmente, mas também pode, se houver interesse, ser

usado para outras finalidades. Para tal, será apenas necessário agregar as demais informações requeridas às futuras aplicações.

Trabalhos recentes (NAMAYANGA, 2002) têm usado informação de estimativa de biomassa para projetar a quantidade de carbono seqüestrado em uma dada área, podendo gerar créditos de carbono. Esta é apenas mais uma das diversas possibilidades para uso desse banco de dados espaciais.

A plataforma escolhida para a execução desse trabalho foi a do *ARCVIEW 3.x*, um software que, apesar de existir versão mais nova, ainda é muito usado nas empresas e no meio acadêmico, pois existem muitas aplicações desenvolvidas nele. Além disso, a aplicação de planejamento energético *MEAPA*, discutida no início deste trabalho, também está desenvolvida nessa mesma plataforma.

Além do aspecto técnico no tratamento da informação, foi de grande importância também a análise de custo-benefício de um sistema com resultados em SIG.

Pelo lado dos custos de um sistema implementado em SIG, tem-se, conforme (PICK, 2005) que a maioria dos custos de um SIG é composta de parcelas tangíveis tais como

- (a) aquisição do software e equipamentos computacionais
- (b) treinamento do pessoal envolvido
- (c) digitalização de mapas e outras informações relevantes
- (d) construção e manutenção da base de dados e das aplicações.

Por outro lado, pelo lado dos benefícios, embora alguns deles sejam intangíveis, muitos se prestam a ser quantificados.

No caso específico de um levantamento para se obter um inventário florestal com a finalidade de se estimar o potencial energético da biomassa existente em uma vasta área amazônica, os custos começam pela própria logística desse empreendimento. Essa tarefa envolve dezenas de profissionais da área de engenharia florestal, com deslocamentos a regiões distantes, às vezes de difícil acesso, tudo envolvendo custos com diárias, transporte e alimentação.

O uso do sistema SIG substitui esse tipo de custo pela aquisição de imagens de satélite de média resolução (faixa de 10 a 30 m, como no LANDSAT) e de um inventário florestal em escala bastante reduzida, com a finalidade de treinamento da rede neural associada.

Entretanto, uma vez treinada a rede neural, ela pode ser usada para o processamento de uma área bem mais vasta do que aquela inventariada, usando-se sua capacidade de aprendizado e generalização. Isso, certamente dá uma economia de escala, diretamente proporcional à área envolvida no estudo.

Na área de planejamento energético com energias renováveis na Amazônia, esse sistema tem como vantagens a capacidade de monitoramento de grandes áreas. Tanto para avaliar capacidade de produção de energia elétrica, como de administração de eventuais florestas energéticas para o abastecimento de comunidades isoladas.

6.2.6 Restrições

A partir de final dos anos 90, satélites mais sofisticados, com uma resolução de pixel da ordem de 1 m a 3 m passaram a operar comercialmente. Exemplos dessa família tecnológica de satélites são o Ikonos e o Quickbird.

Nas imagens desses satélites, em algumas aplicações, o pixel é menor do que o objeto de estudo. Numa resolução de 1 m, um pixel é menor que um ônibus, por exemplo. Isso significa que são necessários vários pixels para se compor um objeto de estudo.

Essa situação está em completo desacordo com os pressupostos teóricos deste trabalho, que por utilizar imagens de média resolução (20 m a 30 m por pixel) lida com o objeto (ou vários deles) contido no pixel e não o inverso.

Devido a essa diferença tecnológica e epistemológica, as ferramentas desenvolvidas para se trabalhar classificação e extração de informação em imagens de média resolução se revelam inúteis para processar essas imagens mais recentes, com essa resolução aumentada. Novas tecnologias e, principalmente, novas abordagens são necessárias para isso e elas estão fora do escopo deste trabalho.

Entre essas novas abordagens e tecnologias, estão a extração de texturas e análise contextual da imagem. Por sua complexidade, exigem computadores com maior capacidade de processamento, uma vez que para uma mesma área, como a resolução é maior, a quantidade de pixels a ser processada é bem maior.

A escolha pelo trabalho com imagens de média resolução foi feita levando-se em conta, primeiro a grande disponibilidade espacial e temporal dessas imagens, além do baixo custo delas. Elas estão disponíveis de forma contínua em um grande período e de todas as partes do mundo, como as do LANDSAT, por exemplo. No caso das imagens do satélite sino-brasileiro CBERS, com resolução de 20m por pixel, elas são cedidas gratuitamente, para pesquisadores, pelo Instituto Nacional de Pesquisas Espaciais (INPE).

A outra restrição diz respeito ao uso do software *ARCVIEW*, já mencionado. No atual momento de nítido crescimento de uso, pelas universidades, de software livre e aberto, o recomendado seria aderir a essa tendência e desenvolver esse sistema em um software integrante dessa plataforma.

Contra isso, entretanto, pesaram dois fatos. O primeiro é que a aplicação *MEAPA*, um sistema de planejamento energético com energias renováveis, um sistema de média complexidade, está desenvolvido na plataforma *ARCVIEW*. Alterar essa plataforma implicaria em reescrever toda essa aplicação no novo ambiente, o que certamente envolve custos adicionais de tempo e esforço.

O segundo fator a pesar contra, é que as plataformas SIG de software livre e aberto disponíveis, ainda são poucas e muito incompletas. A mais conhecida delas é a *PostGIS* que opera em conjunto com o banco de dados relacional *Postgre/SQL*. Esse software, entretanto, carece de muitas das facilidades importantes no *ARCVIEW*. Por isso, uma mudança para essa plataforma, reduziria em muito a operacionalidade do sistema que já funciona.

Capítulo 7

CONCLUSÃO

A crescente necessidade de universalização do acesso à energia elétrica por comunidades isoladas da Amazônia, onde é imensa a dificuldade de chegada de linhas de transmissão, por força das características geográficas da região, e a grande disponibilidade de biomassa, com a possibilidade de ser usada como combustível primário para a produção de energia elétrica de forma distribuída e local exigem das instituições locais de pesquisa, a busca de propostas de solução para essa questão de grande importância técnica, econômica e social.

A necessidade de se fazer inventários florestais para estimativa de volume e de potencial energético de biomassa em regiões como a Amazônia, por um lado e, por outro lado, a disponibilidade de imagens de satélite cobrindo essa região, tem despertado a atenção de pesquisadores para a obtenção de métodos e procedimentos que correlacionem a intensidade da radiação eletromagnética registrada pelos sensores dos satélites com dados florestais obtidos em medições feitas em campo.

Entretanto, muitos desses métodos apresentados nas últimas décadas pressupõem a existência de correlação linear entre as grandezas envolvidas e que não haja colinearidade entre os dados das diversas bandas das imagens de satélite usadas. Experimentalmente, porém, tais pressupostos não têm sido verificados na maioria dos casos, o que motivou pesquisas direcionadas a métodos que não dependessem de tais pressupostos teóricos e epistemológicos.

Nessa direção, ganharam força métodos com base em modelos não-lineares que também não supõem a existência de uma distribuição probabilística conhecida, subjacente aos dados. Entre tais métodos, destacam-se aqueles que têm utilizado as redes neurais artificiais, por suas demonstradas características matemáticas de não-linearidade e de aproximadoras universais de funções contínuas em espaços multidimensionais, a partir de um conjunto finito de dados experimentais de entrada e saída.

Diferenciando-se dos trabalhos anteriores nessa área, este trabalho introduziu um tratamento prévio da imagem de satélite, classificando e agrupando padrões similares de biomassa em agrupamentos distintos em função de suas características, usando para isso a arquitetura de rede competitiva, o Mapa Auto-Organizável de Kohonen. Usou também uma

grande base de dados de inventário de campo como padrão de treinamento em combinação com esses agrupamentos diferenciados de dados, para fazer a correlação não-linear existente entre a resposta eletromagnética registrada pelos sensores em órbita e os dados levantados em campo. A aproximação do modelo funcional desconhecido foi feita com o uso de funções de base radial, que possuem propriedades matemáticas bem conhecidas como aproximadoras universais de funções contínuas em espaços multidimensionais. Finalmente, após os resultados, a imagem de satélite foi novamente classificada, dessa vez, em busca dos padrões de similaridade de volume de biomassa e potencial bioenergético.

Os métodos desenvolvidos e aplicados neste trabalho aplicam-se somente a imagens de satélite de média resolução, na faixa de 20 m a 30 m por pixel, tais como as imagens dos satélites LANDSAT e CBERS. Nas últimas décadas, avanços da tecnologia têm tornado disponíveis comercialmente, imagens de satélite de alta resolução, na faixa de 1 m a 3 m por pixel. Tais imagens, por sua extraordinária riqueza de detalhes, e, principalmente, por mostrarem um objeto de estudo como composto por vários pixels da imagem, ao contrário das outras onde, vários objetos estão contidos em um pixel, demandam novas tecnologias e novos conceitos teóricos e epistemológicos para seu tratamento. Os métodos descritos e usados neste trabalho não se aplicam a imagens com essa resolução.

Finalmente, uma rede treinada para uma determinada área de floresta não pode simplesmente ser usada em outra. Se as tipologias florísticas forem semelhantes, tal uso é possível. Caso contrário, ao se tratar de uma região com características florestais diversas daquela onde a rede neural foi inicialmente treinada, um novo treinamento com dados locais se faz necessário para sua efetiva utilização. E esses dados locais têm que ser coletados, na própria região. Entretanto, o custo associado a esse pequeno inventário é apenas uma fração do custo de um inventário florestal completo na área, o que ainda justifica o uso desta aplicação.

REFERÊNCIAS

- ABNT, 2003. **NBR11941 – Madeira, Determinação da Densidade Básica**. Rio de Janeiro, 2003.
- ADA. Agência de Desenvolvimento da Amazônia. Disponível em www.ada.gov.br. Acessado em 10/junho/2008.
- ALMEIDA, A; MONTEIRO, J. H; ROCHA, B. R. P. Renewable Energy and Social Development in an Amazonian Community. **15th European Biomass Conference**. Berlim, 2007.
- ANDERSON, J. R. A Land Use and Land Cover Classification System for Use with Remote Sensor Data. **United States Geological Survey Professional Paper 964**. 1976.
- ASTM, 2002. **Standard Test Methods for Specific Gravity of Wood and Wood-based Materials**. ASTM International. West Conshohocken. USA,
- AYRES, M; AYRES JR, M; AYRES, D; SANTOS, A. S. **BIOESTAT 3.0 – Aplicações Estatísticas nas Áreas das Ciências Biológicas e Médicas**. Belém, UFPA. 2003
- BARRETT, R. A. The Paradoxical Anthropology of Leslie White. **American Anthropologist**. **91**:986-999, 1989.
- BETTINGER, P; HAYASHI, R. Estimation of Above-ground Biomass With Remotely Sensed Imagery: A Brief Literature Review. **Center for Forest Business. Research Note 25**. University of Georgia. 2006.
- BISHOP, C. M. **Neural Networks for Pattern Recognition**. Oxford University Press. Oxford, 1995.
- BECK, W; LIEN, K; SIMPSON, G. **LIFE: An Introduction to Biology**. Harper Collins, USA, 3d ed. 1991.
- BRASIL. Departamento Nacional de Produção Mineral. Projeto Radam. **Folhas SA-22 Belém: geologia, geomorfologia, solos, vegetação e uso potencial da terra**. Rio de Janeiro, 1974.
- CAMARA, G, FREITAS, R. C. M. SPRING: Integrating remote sensing and GIS by object-oriented data modeling. **Journal of Computers & Graphics**, 20: (3) 395-403, May-Jun 1996.
- CÂMARA, G; MEDEIROS, J. S. Princípios Básicos de Geoprocessamento. In: ASSAD, E.D; SANO, E.E; **Sistemas de Informações Geográficas: Aplicações na Agricultura**. Embrapa. Brasília, 1998.
- CAMPOS, J. C. C; TORQUATO, M. C; RIBEIRO, G. A. Equações para Calcular Índices de Local e Incremento da Altura de Plantações Puras de *Eucalyptus grandis*. **Revista Árvore**. V.9, 1985.

CCRS. **Fundamentals of Remote Sensing**. Canadian Centre for Remote Sensing. Canada. 2000.

CHEN, S; COWAN, F; GRANT, M. Orthogonal least squares learning algorithm for radial basis function networks. In: **Artificial Neural Networks: Concepts and Control Applications**. IEEE Society Press, USA, 1992..

DEMUTH, H; BEALE, M. **Neural Network Toolbox for Use With MATLAB**. The Mathworks, Inc. USA, 2002.

DEVANEY, R. L. **An Introduction to Chaotic Dynamical Systems**, Menlo Park. CA. 1996.

EGMONT-PETERSEN, M; RIDDER, D; HANDELS, H. Image Processing With Neural Networks – A Review. **Pattern Recognition**, vol. 35, pp 2279-2301, Ed. Pergamon, 2002.

ELETRONORTE. **Estudos Ambientais Associados à Elevação do Nível D'água do Reservatório Até à Cota 74. Caracterização Ambiental – Flora**. Brasília, 2001.

FERRARI, S; STENGEL, R. Smooth Function Approximations Using Neural Networks. **IEEE Transactions on Neural Networks**. Vol 16, no. 1, 2005.

FRATE, F; SOLIMINI, D. On the Retrieval of Forest Biomass from SAR Data by Neural Networks. **Proc. IEEE**, IEEE Society Press, USA, 2003.

FRATE, F; SOLIMINI, D. On Neural Networks Algorithms for Retrieving Forest Biomass from SAR Data. **IEEE Transactions on Geoscience and Remote Sensing**. Vol. 42, 2004.

FREITAS, S. R; MELLO, M. C. S; CRUZ, C. B. Relationships Between Forest Structure and Vegetation Indexes in Atlantic Rainforest.. **Forest Ecology and Management**. 218, 2005.

GJERTSEN, A. K. Accuracy of Forest Mapping Based On Landsat TM Data and a k-nn Based Method. **Remote Sensing of Environment**. 110, 420-430. 2007

GOLDEMBERG, J; VILLANUEVA, L. **Energia, Meio Ambiente & Desenvolvimento**. Edusp. 2^a. ed, SP, 2003.

GOSWAMI, Y. D; KREITH, F. **Energy Conversion**. CRC Press, New York, 2007.

GRAUBE, D. **Principles of Neural Networks**. World Scientific, 2nd Ed. Singapore, 2007.

HAYKIN, S. **Redes Neurais, Princípios e Prática**. Ed. Bookman, Porto Alegre, 2001.

IBGE. Disponível em www.ibge.gov.br/home/estatisticas/indicadores/pib/pdf/16.energia.pdf. Acessado em 10/06/2008

INGRAM, J. C; DAWSON, T. P; WHITTAKER, R. J. Mapping Tropical Forest Structure in Southeastern Madagascar Using Remote Sensing and Artificial Neural Networks. **Remote Sensing of Environment**, 94, 491-507. 2005.

IPCC. **Climate Change Synthesis Report: 2007**. Intergovernmental Panel on Climate Change. 2007

JANNUZZI, G. M. **Tools and Methods for Integrated Resource Planning: Improving Energy Efficiency and Protecting the Environment**. UNEP. 1997. Online Edition.

JENSEN, J. R; QIU, F; JI, M. Predictive Modeling of Coniferous Forest Age Using Statistical and Artificial Neural Networks Approaches to Remote Sensor Data. **International Journal of Remote Sensing**. 20, 1999.

JENSEN, J. R. **Remote Sensing of the Environment: an Earth Resource Perspective**. Prentice-Hall, USA, 2000.

KOHONEN, T. The Self Organizing Map. In: **Artificial Neural Networks: Concepts and Control Applications**. IEEE Society Press, USA, 1992.

KORTE, G. B. **The GIS Book**. Onword Press, New York, 2000.

LILLESAND, T; KIEFER, R. **Remote Sensing and Image Interpretation**. 5th ed. John Wiley & Sons. New York. 2004.

LIPPMANN, R. P. An Introduction to Computing with Neural Nets. In: **Artificial Neural Networks: Concepts and Control Applications**. IEEE Society Press. USA, 1992.

LORENZ, E. N. **A Essência do Caos**. Ed. UnB. Brasília, 1996.

LU, D; MAUSEL, P; BRONDIZIO, E; MORAN, E. Above-ground Biomass Estimation of Successional and Mature Forests Using TM Images in the Amazon Basin. **Symposium on Geospatial Theory, Processing and Applications**. Ottawa, Canada, 2002.

LU, D. The Potential and Challenge of Remote-sensing Based Biomass Estimation. **International Journal of Remote Sensing**,. 27, 2006.

MIGUEZ, J. Disponível em www.mct.gov.br. Acessado em 10/06/2008.

MME - **Luz Para Todos. Manual de Operacionalização**. Brasília, 2004.

MME – **Balço Energético Nacional**, Brasília, 2007

MONTEIRO, C; SARAIVA, J. T; MIRANDA, V. Evaluation of Electrification Alternatives in Developing Countries – The SOLARGIS Tool. **9th Mediterranean Electrotechnical Conference**. Israel. 1998

NAMAYANGA, L. N. **Estimating Terrestrial Carbon Sequestered in Aboveground Woody Biomass From Remotely Sensed Data**. Dissertação de Mestrado. International Institute for Geo-Information Science and Earth Observation. The Netherlands. 2002

NASA. Disponível em <http://landsat.gsfc.nasa.gov>. Acessado em 10/06/2008.

NISHIDA, W; BASTOS, L. C. Classificação de Imagens de Sensoriamento Remoto Utilizando uma Rede Neural Artificial com Função de Base Radial. **Anais do IX Simpósio Brasileiro de Sensoriamento Remoto**. Santos-Sp, 1998.

OLIVEIRA, Adilson - **Energia e Desenvolvimento Sustentável**. Relatório Final. Eletrobrás. 1998

ORMSBY, Tim – **Extending ARCVIEW GIS**. ESRI Press, 1999.

PANDA, S. S; GARG, V; CHAUBEY, I. Artificial Neural Networks Application in Lake Water Quality Estimation Using Satellite Imagery. **Journal of Environment Informatics** . V 4, 2004.

PARKS, P. J. **Global Warming**. Ed. Thomson, Gale. London. 2004.

PICK, J. B. **Geographic Information Systems in Business**. Idea Group Publishing, London, 2005.

POGGIO, T; GIROSI, F. Networks for Approximation and Learning. In: **Artificial Neural Networks: Concepts and Control Applications**. IEEE Society Press, USA, 1992.

QUAAK, P; KNOEF, H; STASSEN, H. Energy from biomass: A review of combustion and gasification technologies. **World Bank Technical Paper 422**. USA, 1999.

QUIOTO. Disponível em
<<http://www.mct.gov.br/index.php/content/view/17331.html>>.
Acessado em 10/06 /2008

REIS, L. B. **Energia Elétrica para o Desenvolvimento Sustentável**. Edusp. Sp. 2001.

ROCHA, B. R. P; SILVA, I. M. O; PINHEIRO, E. C. L; ROCHA, A. O. F; MORAES, S. B; MONTEIRO, C; LOPES. J. P. Metodologias Integradas para o Mapeamento de Energias Alternativas no Estado do Pará. **Actas do 4º Encontro Luso-Afro-Brasileiro de Planejamento e Exploração de Redes de Energia**, Rio de Janeiro-RJ, Brasil, 1999.

ROCHA, B. R. P; SILVA, I. M. O. Energia Elétrica para o Desenvolvimento Sustentável. 2000.

SAATCHI, S. S; HOUGHTON, R. A; ALVALA, R. C. S; SOARES, J. V; YO, Y. Distribution of Aboveground Live Biomass in the Amazon Basin. **Global Change Biology**, 2006.

SABINS, Floyd F. **Remote Sensing: Principles and Interpretation**. 3d ed. W H Freeman, New York, 1996;

SILVA, I. M. O. **Um Estudo Sobre a Sustentabilidade Energética na Ilha do Marajó, Estado do Pará**. Tese de Doutorado. UFPA, 2003.

SILVA, I. T; ALMEIDA, A. C; ROCHA, B. R. P. Uso do Carço de Açái como Possibilidade de Desenvolvimento Sustentável do Meio Rural, da Agricultura Familiar e de Eletrificação Rural no Estado do Pará. In: **AGRENER - GD 2004, 2004**, Campinas - SP. Anais do AGRENER - GD 2004, 2004.

SIMÔES, M. G; FARRETT, F. A. **Integration of Alternative Sources of Energy**. John Wiley & Sons. 2006.

STRANG, G. **Linear Algebra and its Applications**. Brooks-Cole Thomson Learning, 3d. Edition. New York, 1988.

UNESCO. **Carta da Terra**. 2000.

USAID. Disponível em

< <http://www.canalenergia.com.br/zpublisher/materias/PeD.asp?id=37337>>.

Acessado em 10/06/2008.

DEMURI, V. R (Org.), **Artificial Neural Networks: Concepts and Control Applications**. IEEE Society Press, USA, 1992.

VENTURIERI, A; SANTOS, J. R. Técnicas de Classificação de Imagens para Análise de Cobertura Vegetal, In: ASSAD, E. D; SANO, E.E. **Sistemas de Informações Geográficas: Aplicações na Agricultura**. Embrapa. Brasília, 1998.

WERBOS, P. J. An overview of neural networks for control. In: **Artificial Neural Networks: Concepts and Control Applications**. IEEE Society Press, USA, 1992.

WIDROW, B; HOFF, M. E. Adaptive Switching Circuits. **WESCON Convention Records 4**. 1960.

ZHENG, D. et al. Estimating Aboveground Biomass Using LANDSAT 7 ETM Data Across a Managed Landscape in Northern Wisconsin, USA. **Remote Sensing of Environment**, v.3,3, pp 402-411, Ed. Elsevier, 2004.

APÊNDICE A

RESULTADOS DE CAMPO

Tabela 5 - Planilha com dados de inventário florestal usado para entrada na rede neural

PARC	B1	B2	B3	B4	NDVI	ALTURA	ÁREA BASAL	VOLUME
101	71	62	50	107	0.363057	13.8	17.704	406.073
102	67	63	52	106	0.341772	8.8	4.173	49.621
103	76	69	57	106	0.300613	11.3	9.022	133.452
104	83	76	69	108	0.220339	10.4	1.581	20.807
105	83	73	65	106	0.239766	12.8	3.43	54.712
106	76	68	60	104	0.268293	11.6	1.427	21.615
107	82	71	64	104	0.238095	13.4	2.702	41.253
108	73	64	54	92	0.260274	13.8	1.732	25.454
109	65	52	42	71	0.256637	12.1	2.078	28.003
110	62	52	44	68	0.214286	11.6	1.402	19.385
111	65	58	46	90	0.323529	9.7	5.375	53.137
112	66	60	46	89	0.318519	12.3	3.26	42.098
113	65	62	51	96	0.306122	10.6	1.874	21.864
114	66	62	49	94	0.314685	12.1	2.47	28.194
201	60	57	45	82	0.291339	11	3.326	35.687
202	60	57	46	81	0.275591	11.4	3.172	36.442
203	60	54	45	82	0.291339	9.8	2.658	28.216
204	59	55	46	83	0.286822	10.4	1.519	15.355
205	60	54	47	84	0.282443	10.9	1.267	13.071
206	63	48	34	86	0.433333	11	2.391	24.606
207	64	49	35	88	0.430894	11.3	1.83	20.411
208	60	48	32	93	0.488	10.8	1.2	10.566
209	60	48	36	95	0.450382	8.4	1.542	12.98
210	64	48	32	95	0.496063	11.8	6.262	103.06
211	62	48	32	96	0.5	12.3	5.231	71.668
212	62	51	37	96	0.443609	9.4	2.568	21.947
213	63	54	36	94	0.446154	8.6	3.591	32.633
214	68	49	36	107	0.496503	11.3	1.743	15.862
301	76	58	46	79	0.264	10.7	2.523	28.996
302	77	56	47	79	0.253968	10.2	1.522	17.752
303	74	58	47	79	0.253968	13.1	6.055	124.791
303	76	58	47	82	0.271318	12	2.195	29.181
305	78	58	49	83	0.257576	12	14.186	224.24
306	75	59	48	76	0.225806	9.8	3.215	40.649
307	78	58	49	80	0.24031	11.2	2.376	30.461
308	81	58	47	78	0.248	10.5	4.226	41.42
309	77	61	49	76	0.216	13	3.087	47.306
310	79	63	52	80	0.212121	12.1	2.803	32.523
311	77	58	47	77	0.241935	8.7	4.286	31.74
312	76	61	49	75	0.209677	11.1	3.764	28.471
313	81	59	49	77	0.222222	12.3	3.874	40.532
314	76	60	50	71	0.173554	10.7	5.327	62.749

PARC	B1	B2	B3	B4	NDVI	ALTURA	ÁREA	
							BASAL	VOLUME
401	68	57	42	91	0.368421	8.8	4.308	48.092
402	67	56	40	94	0.402985	10	3.396	38.805
403	66	58	42	97	0.395683	9	2.588	23.358
404	69	57	46	91	0.328467	7.4	5.262	66.306
405	64	53	39	73	0.303571	11.3	2.437	27.864
406	68	56	43	81	0.306452	7.1	1.599	21.189
407	66	59	43	83	0.31746	9.8	3.341	35.489
408	67	55	43	80	0.300813	7.5	3.396	28.782
409	66	54	39	75	0.315789	8.8	5.994	78.43
410	62	46	33	52	0.223529	7.5	2.029	20.565
411	64	47	35	50	0.176471	9.4	3.293	32.864
412	62	45	34	45	0.139241	6.3	1.486	8.392
413	63	43	34	45	0.139241	7.8	3.864	22.741
414	60	43	31	42	0.150685	8.6	4.837	30.474
501	68	49	39	58	0.195876	10.4	6.913	94.851
502	68	48	37	57	0.212766	10.9	1.767	18.399
503	68	48	37	60	0.237113	11.5	4.563	63.139
504	69	49	37	60	0.237113	12.7	5.641	85.526
505	69	51	41	61	0.196078	8.1	1.583	12.123
506	68	49	42	63	0.2	9.3	2.36	31.412
507	68	50	37	55	0.195652	5.6	0.9	4.684
508	68	47	41	52	0.11828	7.5	2.14	17.196
509	68	48	39	49	0.113636	9.4	2.531	31.205
510	67	47	37	49	0.139535	8.2	2.572	22.552
511	68	48	35	50	0.176471	7.3	5.293	43.823
512	67	47	36	48	0.142857	10.2	3.874	33.394
513	66	46	39	46	0.082353	7.8	6.334	48.471
514	68	46	33	46	0.164557	5.2	6.396	35.505
601	86	72	58	81	0.165468	12.2	2.882	38.051
602	88	69	55	81	0.191176	14.5	3.289	50.365
603	88	67	62	77	0.107914	13	2.636	37.652
604	89	70	57	82	0.179856	11.6	4.419	69.915
505	91	68	65	89	0.155844	11.2	4.379	53.819
606	91	71	60	87	0.183673	10.9	4.049	45.444
607	91	69	64	86	0.146667	10.5	6.518	85.301
608	95	71	63	87	0.16	12.6	5.706	84.01
609	93	72	65	86	0.139073	12.5	4.502	73.222
610	99	75	70	92	0.135802	13.3	7.165	107.845
611	116	80	85	90	0.028571	12.4	5.349	71.389
612	127	95	103	93	-0.05102	10.9	4.839	43.472
613	139	107	115	98	-0.07981	11.8	3.728	36.582
614	117	117	91	100	0.04712	12.1	2.473	26.849
701	75	57	47	80	0.259843	10.6	2.1	22.986
702	72	57	44	83	0.307087	10.7	2.696	30.051
703	72	60	48	78	0.238095	10.8	2.704	33.447
704	78	63	58	73	0.114504	10.6	2.573	32.555
705	77	66	60	77	0.124088	11.9	2.8	40.028
706	80	65	66	78	0.083333	9.6	2.48	27.32
707	80	70	68	78	0.068493	12.1	2.34	25.438
708	78	66	66	81	0.102041	8.7	2.47	31.873

PARC	B1	B2	B3	B4	NDVI	ALTURA	ÁREA	
							BASAL	VOLUME
709	77	67	67	78	0.075862	11.2	2.843	34.258
710	82	73	73	87	0.0875	9.8	2.014	23.763
711	77	62	56	79	0.17037	9.4	2.343	25.874
712	75	61	53	90	0.258741	11.1	3.012	37.485
713	76	62	52	94	0.287671	12.3	1.874	32.484
714	71	59	48	100	0.351351	11.6	2.946	28.749
801	58	42	27	78	0.485714	3.8	0.05	4.216
802	77	66	77	72	-0.03356	7.5	0.329	9.098
803	60	45	37	67	0.288462	7.2	0.28	15.619
804	58	42	31	76	0.420561	8.2	0.426	3.187
805	72	50	40	23	-0.26984	4.8	0.393	3.983
806	58	41	28	70	0.428571	5	0.011	3.788
807	87	66	56	73	0.131783	3	0.118	3.439
808	65	57	48	92	0.314286	0.1	0	0
809	63	55	37	106	0.482517	0.1	0	0
810	60	37	26	10	-0.44444	1	0	0
811	59	37	25	10	-0.42857	1	0	0
812	66	40	32	19	-0.2549	1	0	0

PARC indica o número da parcela da amostra do inventário florestal realizado

B1 é o valor de refletância da banda 1 encontrado na imagem de satélite, no centro da área.

B2 é o valor de refletância da banda 2 encontrado na imagem de satélite, no centro da área.

B3 é o valor de refletância da banda 3 encontrado na imagem de satélite, no centro da área.

B4 é o valor de refletância da banda 4 encontrado na imagem de satélite, no centro da área.

NDVI é o valor do índice de vegetação normalizado calculado entre as bandas 3 e 4.

ALTURA é o valor médio da altura (m) das árvores encontradas naquela amostra.

AREA BASAL é o valor da área basal (m²/ha) encontrado naquela amostra de inventário.

VOLUME é o valor do volume total (m³/0,25ha) encontrado naquela amostra do inventário.

APÊNDICE B

RESULTADOS DE VOLUME DE BIOMASSA

LISTA DE FIGURAS DO APÊNDICE B

Figura 39 – Mapa A1 (1 de 8) mostrando volume estimado de biomassa	119
Figura 40 - Mapa A2 (2 de 8) mostrando volume estimado de biomassa	120
Figura 41 - Mapa A3 (3 de 8) mostrando volume estimado de biomassa	121
Figura 42 - Mapa A4 (4 de 8) mostrando volume estimado de biomassa	122
Figura 43 - Mapa B1 (5 de 8) mostrando volume estimado de biomassa	123
Figura 44 - Mapa B2 (6 de 8) mostrando volume estimado de biomassa	124
Figura 45 - Mapa B3 (7 de 8) mostrando volume estimado de biomassa	125
Figura 46 - Mapa B4 (8 de 8) mostrando volume estimado de biomassa	126

TUCURUÍ - Volume de Biomassa (m³/ha)

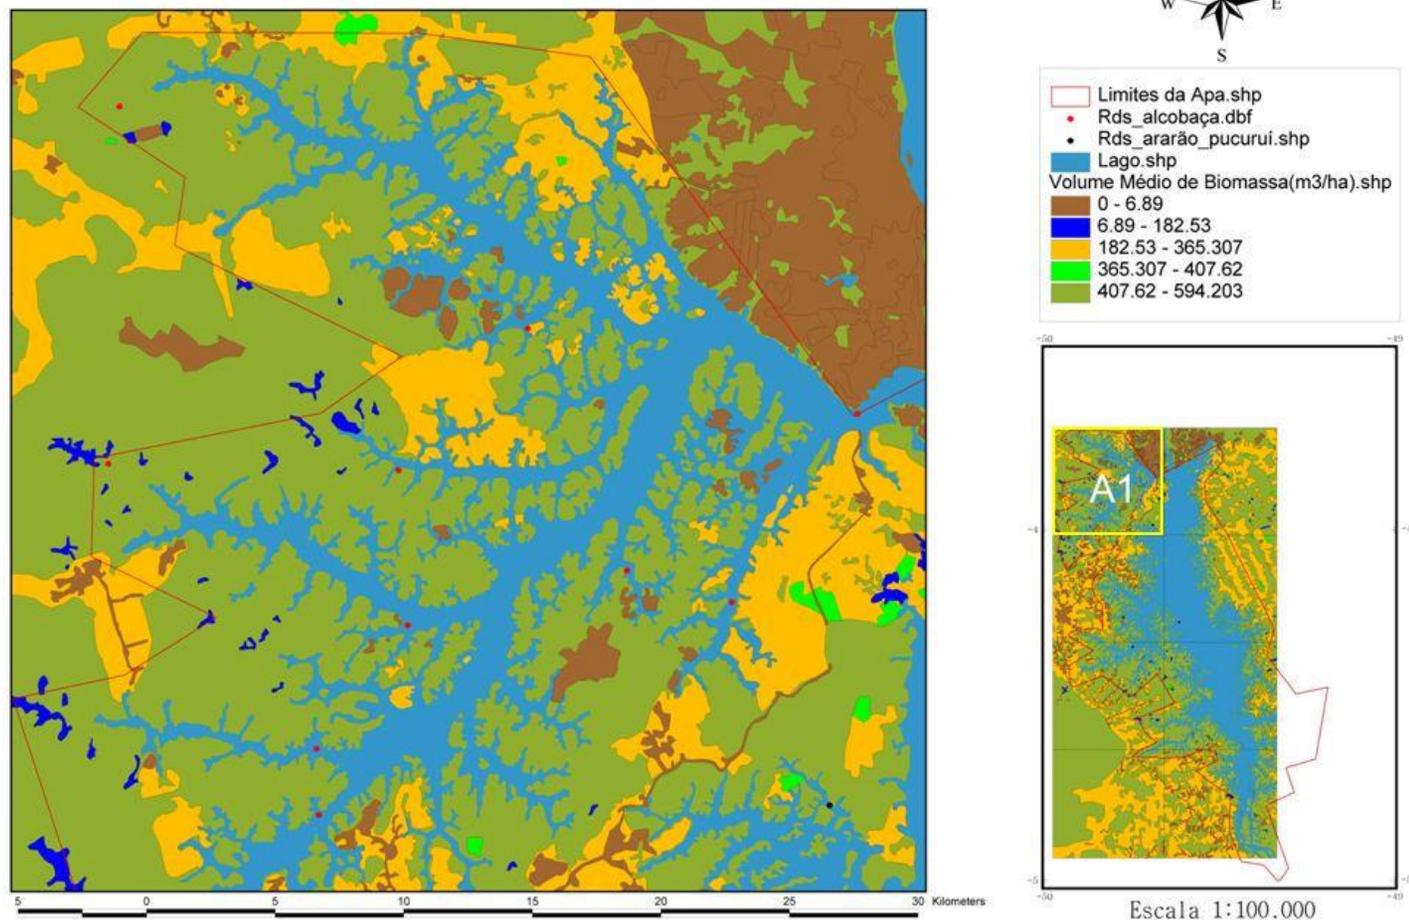


Figura 39 – Mapa A1 (1 de 8) mostrando volume estimado de biomassa

TUCURUÍ - Volume de Biomassa (m³/ha)

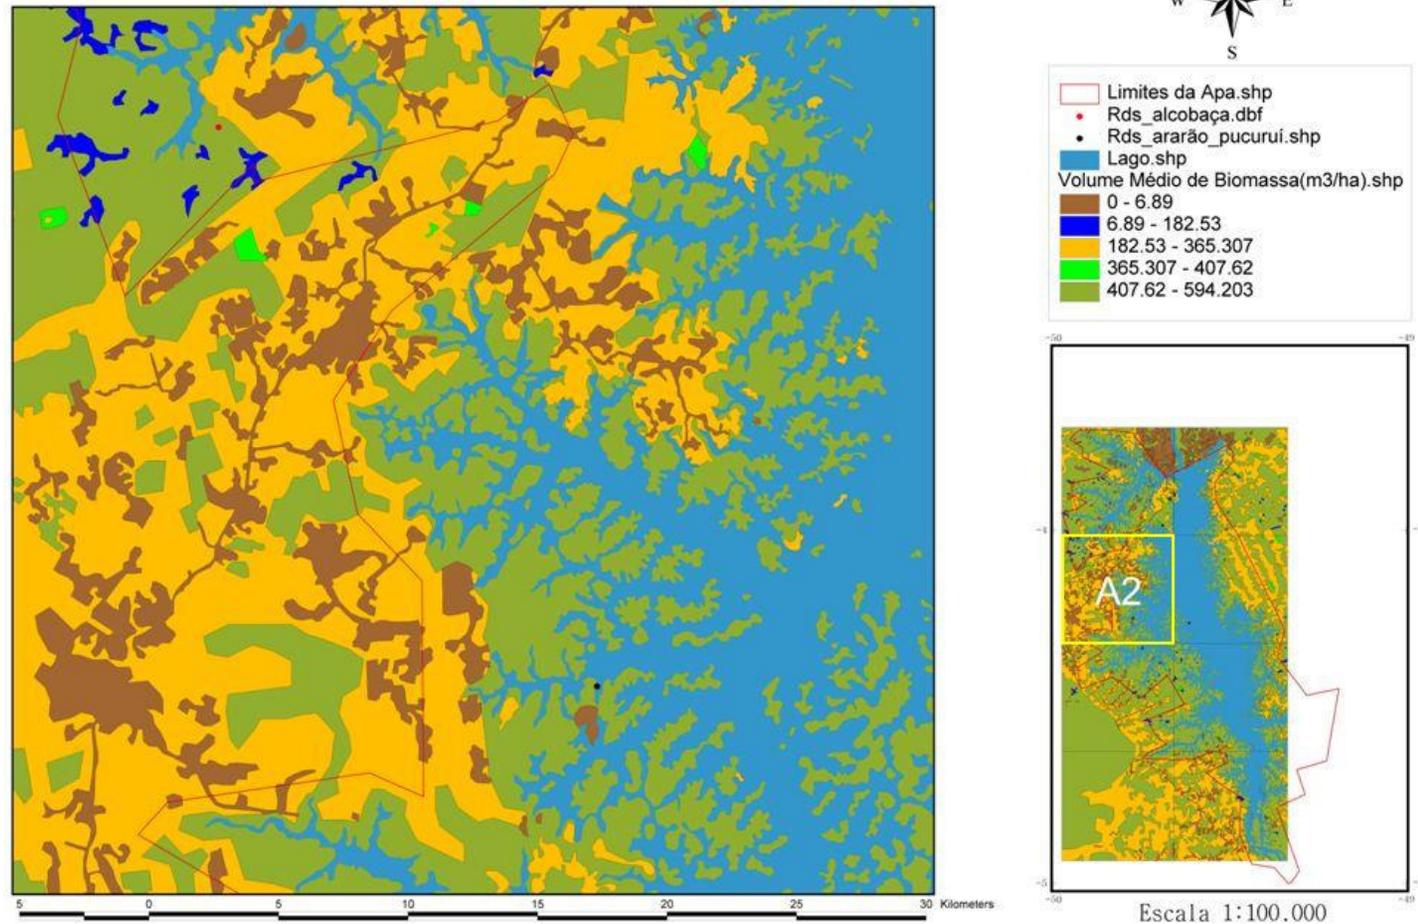


Figura 40 - Mapa A2 (2 de 8) mostrando volume estimado de biomassa

TUCURUÍ - Volume de Biomassa (m³/ha)

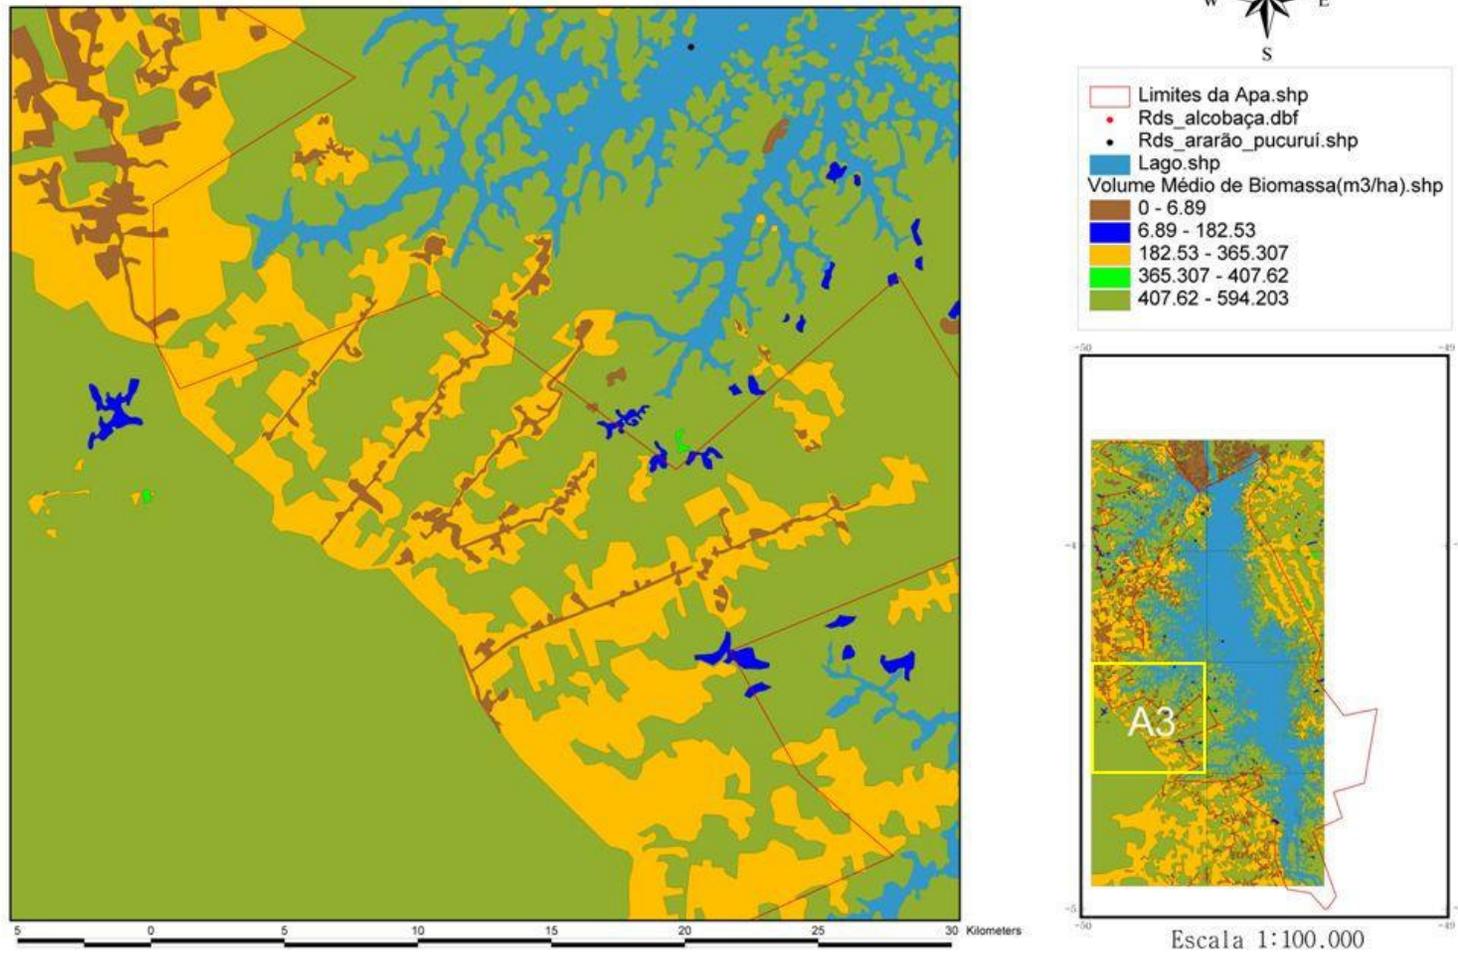


Figura 41 - Mapa A3 (3 de 8) mostrando volume estimado de biomassa

TUCURUÍ - Volume de Biomassa (m³/ha)

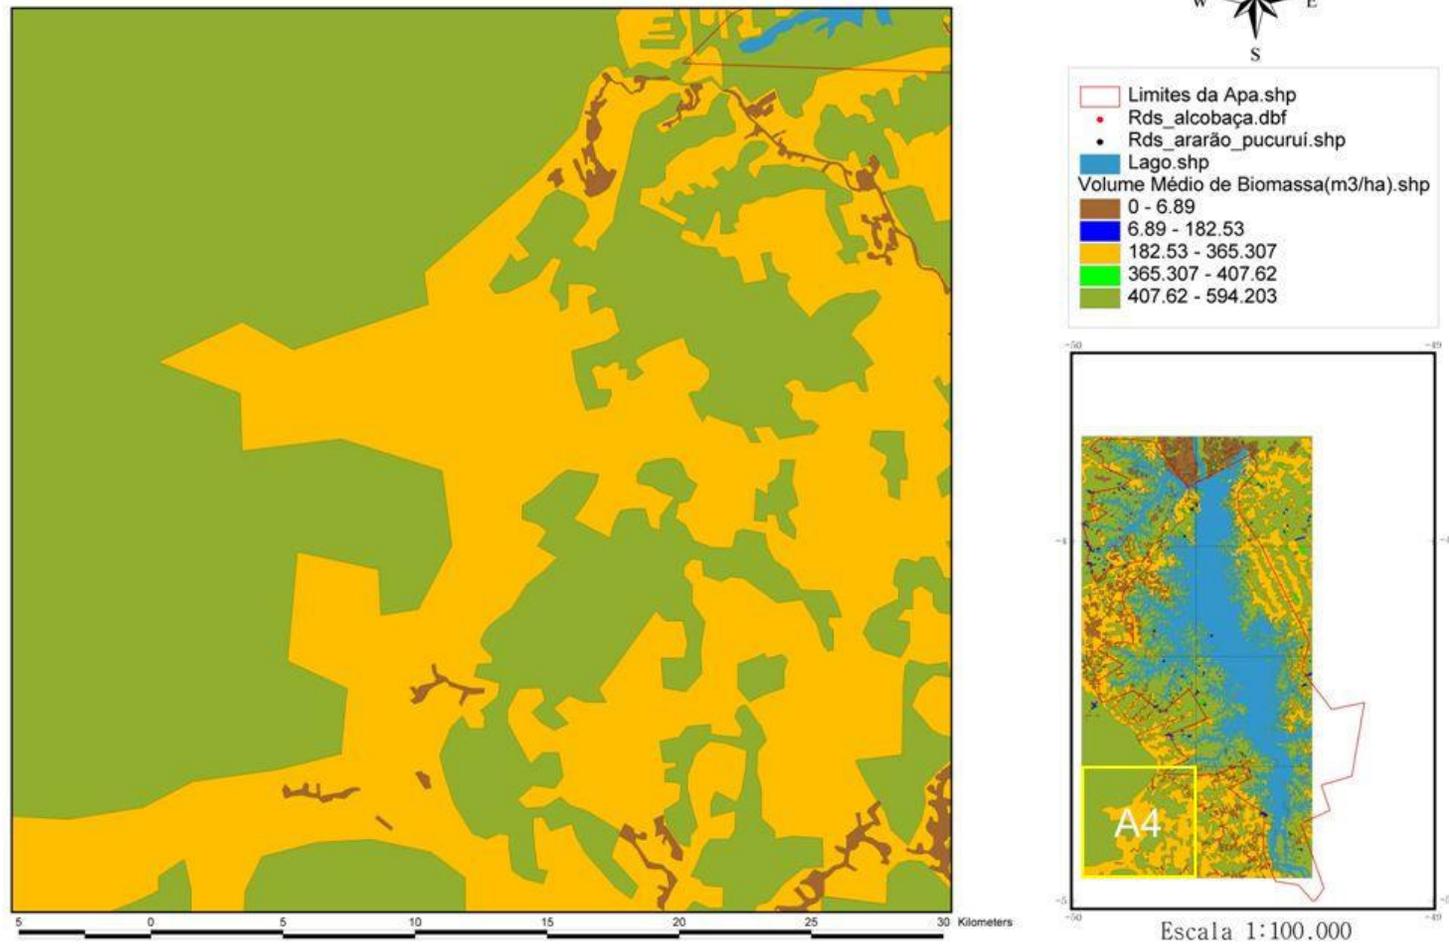


Figura 42 - Mapa A4 (4 de 8) mostrando volume estimado de biomassa

TUCURUÍ - Volume de Biomassa (m³/ha)

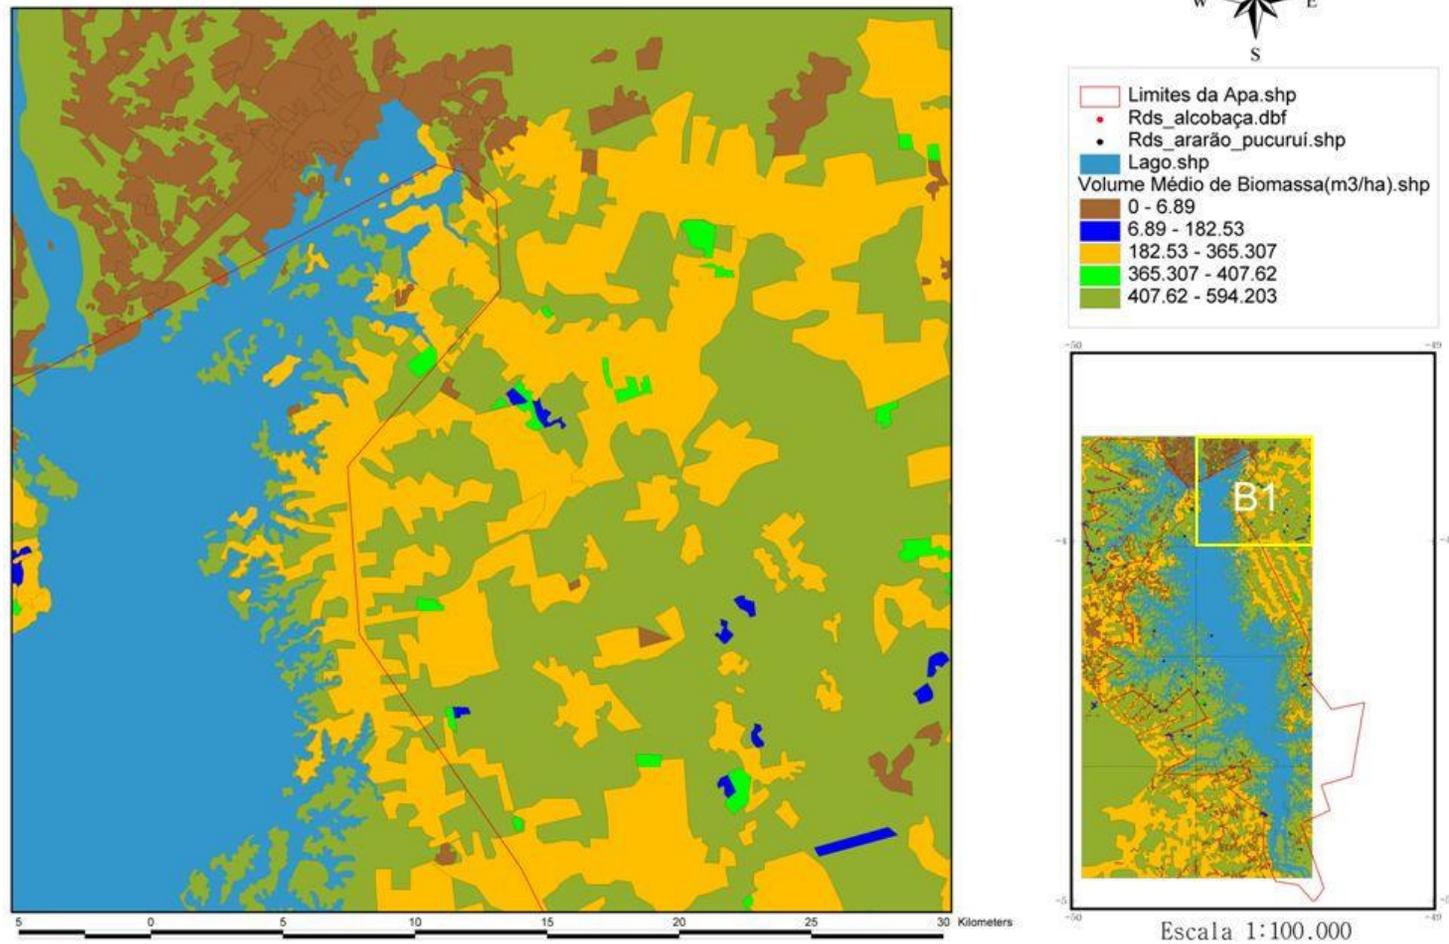


Figura 43 - Mapa B1 (5 de 8) mostrando volume estimado de biomassa

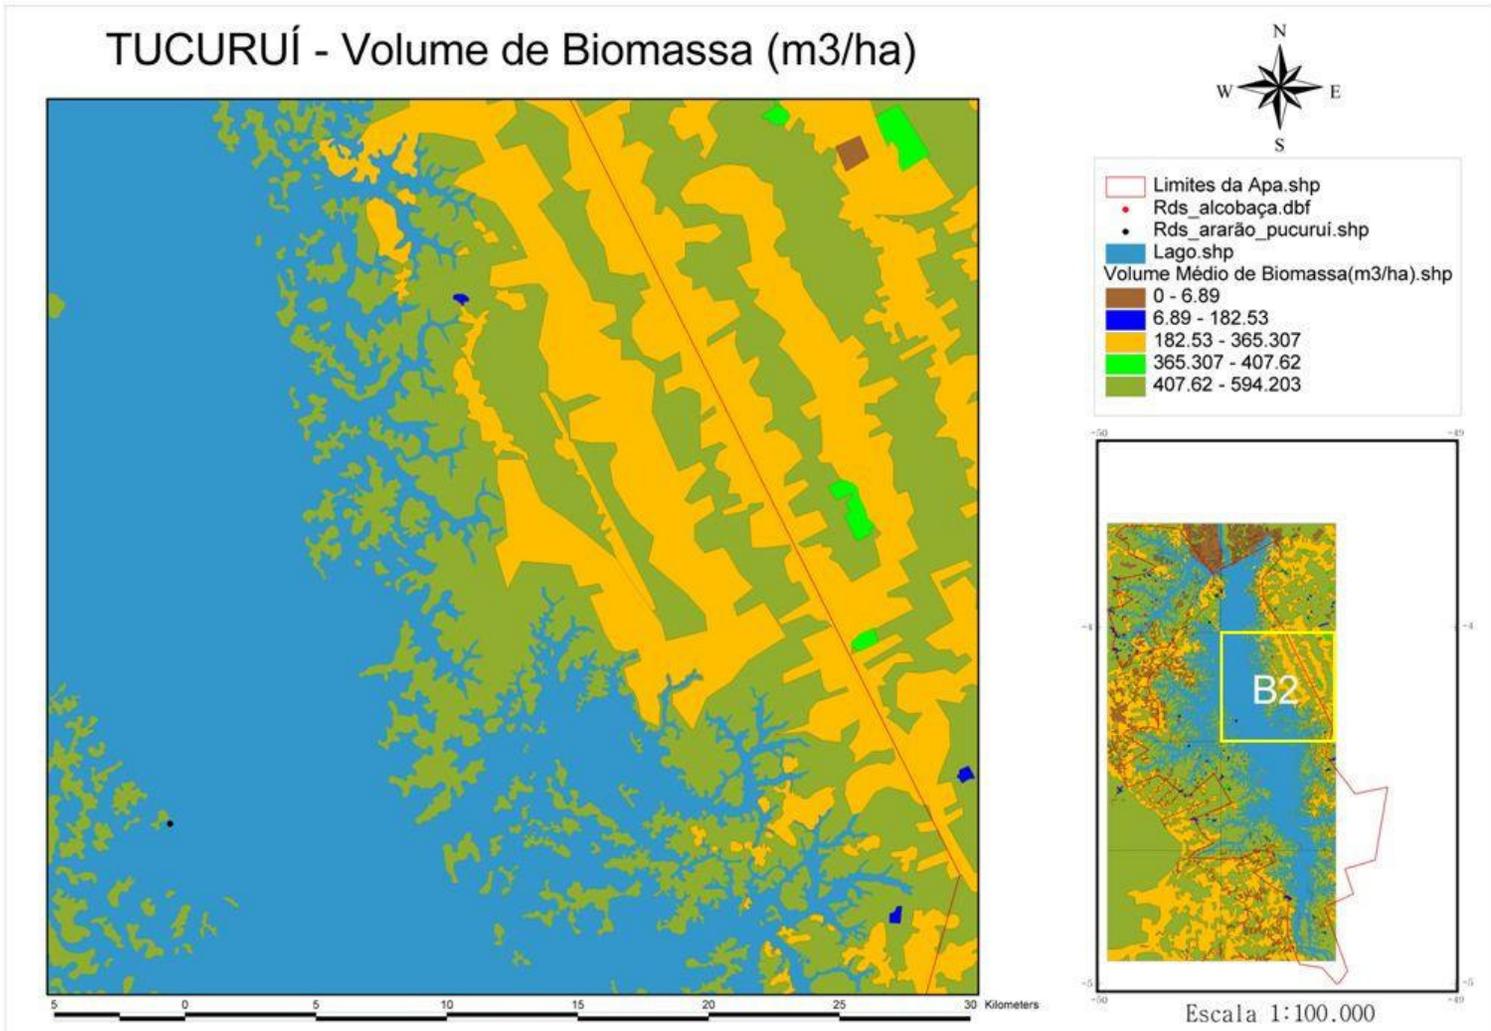


Figura 44 - Mapa B2 (6 de 8) mostrando volume estimado de biomassa

TUCURUÍ - Volume de Biomassa (m³/ha)

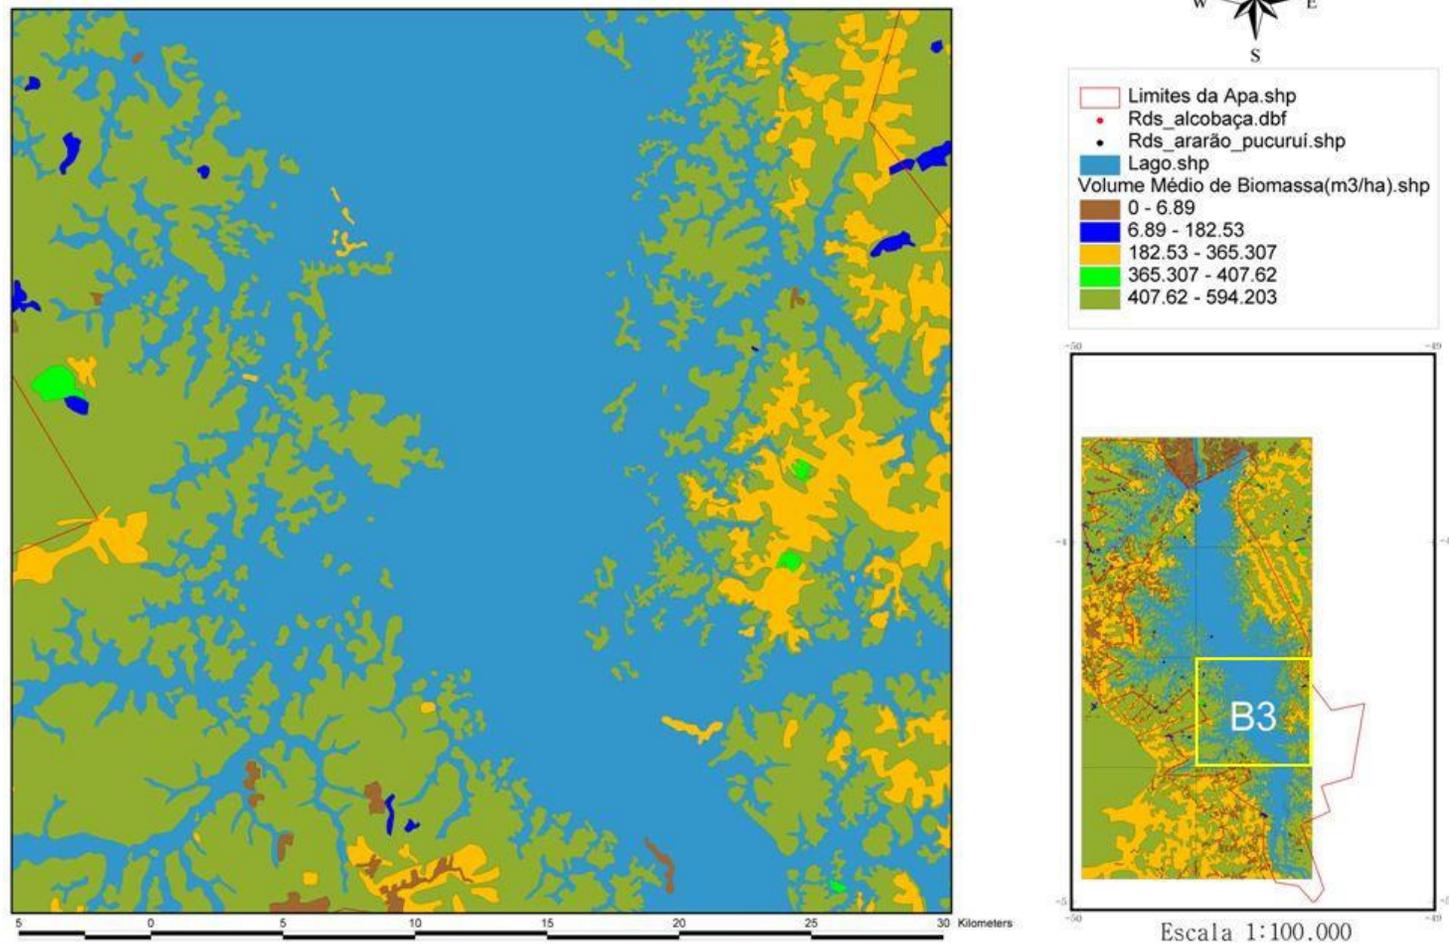


Figura 45 - Mapa B3 (7 de 8) mostrando volume estimado de biomassa

TUCURUÍ - Volume de Biomassa (m³/ha)

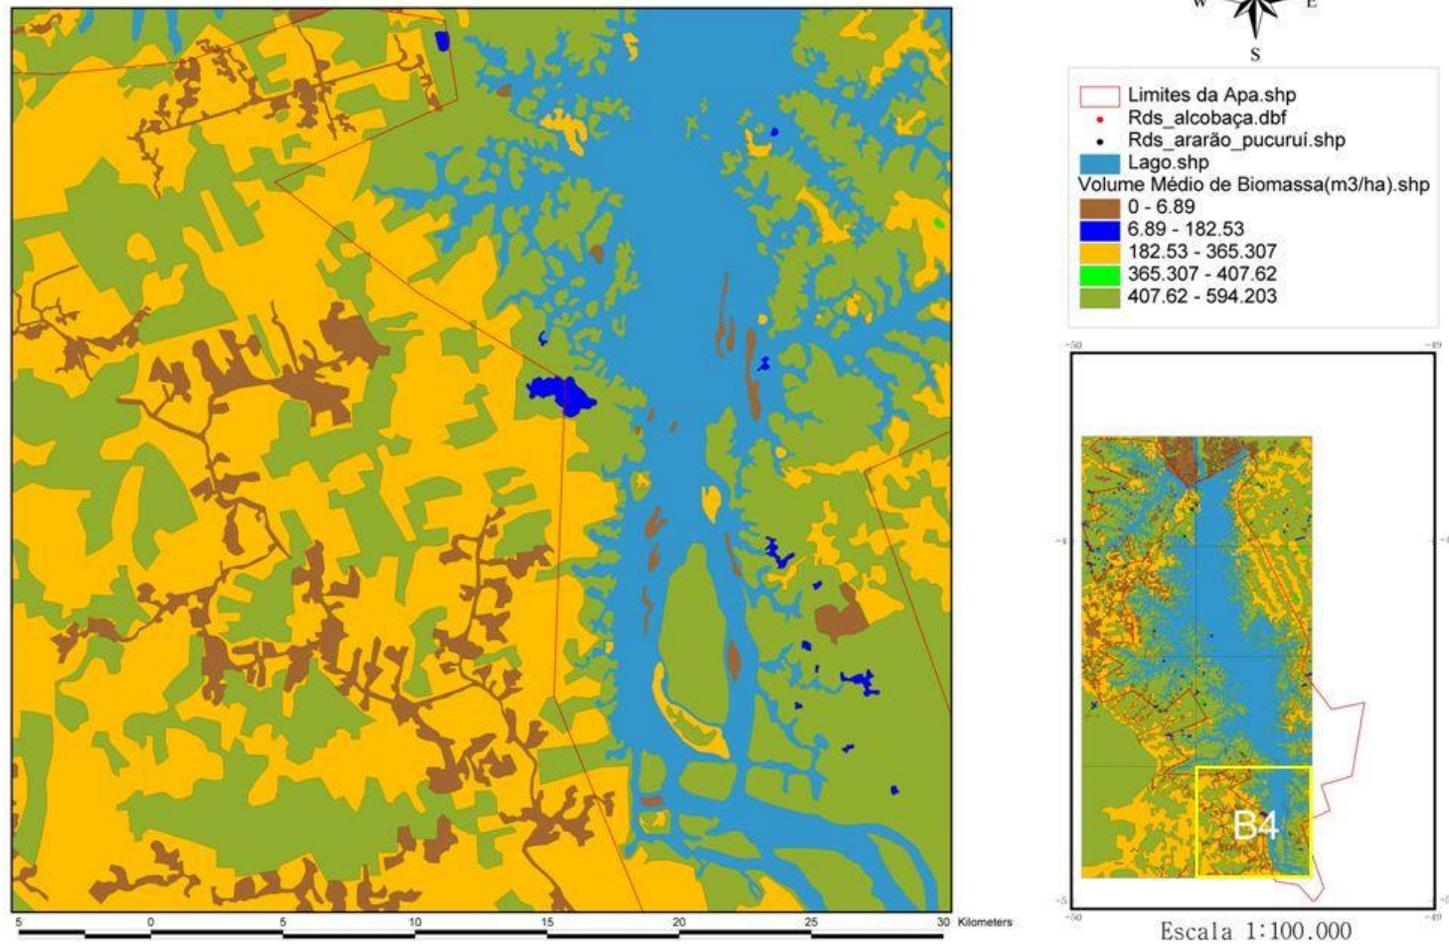


Figura 46 - Mapa B4 (8 de 8) mostrando volume estimado de biomassa

APÊNDICE C

RESULTADOS DE POTENCIAL BIOENERGÉTICO

LISTA DE FIGURAS DO APÊNDICE C

Figura 47 - Mapa A1 (1 de 8) mostrando volume estimado de potencial energético	128
Figura 48 - Mapa A2 (2 de 8) mostrando volume estimado de potencial energético	129
Figura 49 - Mapa A3 (3 de 8) mostrando volume estimado de potencial energético	130
Figura 50 - Mapa A4 (4 de 8) mostrando volume estimado de potencial energético	131
Figura 51 - Mapa B1 (5 de 8) mostrando volume estimado de potencial energético	132
Figura 52 - Mapa B2 (6 de 8) mostrando volume estimado de potencial energético	133
Figura 53 - Mapa B3 (7 de 8) mostrando volume estimado de potencial energético	134
Figura 54 - Mapa B4 (8 de 8) mostrando volume estimado de potencial energético	135

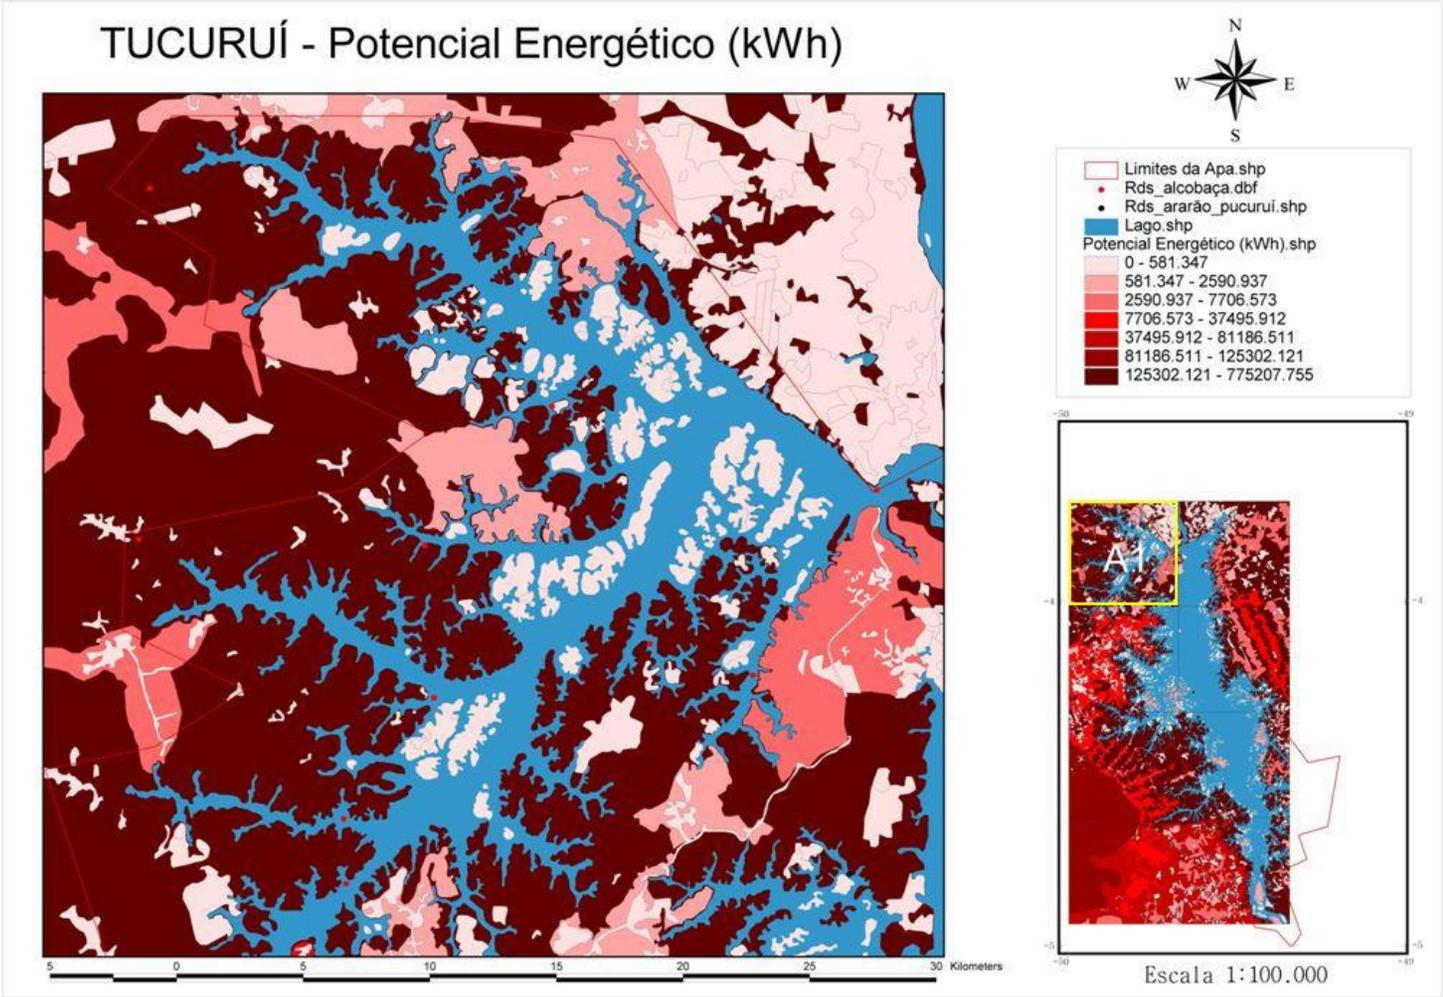


Figura 47 - Mapa A1 (1 de 8) mostrando volume estimado de potencial energético

TUCURUÍ - Potencial Energético (kWh)

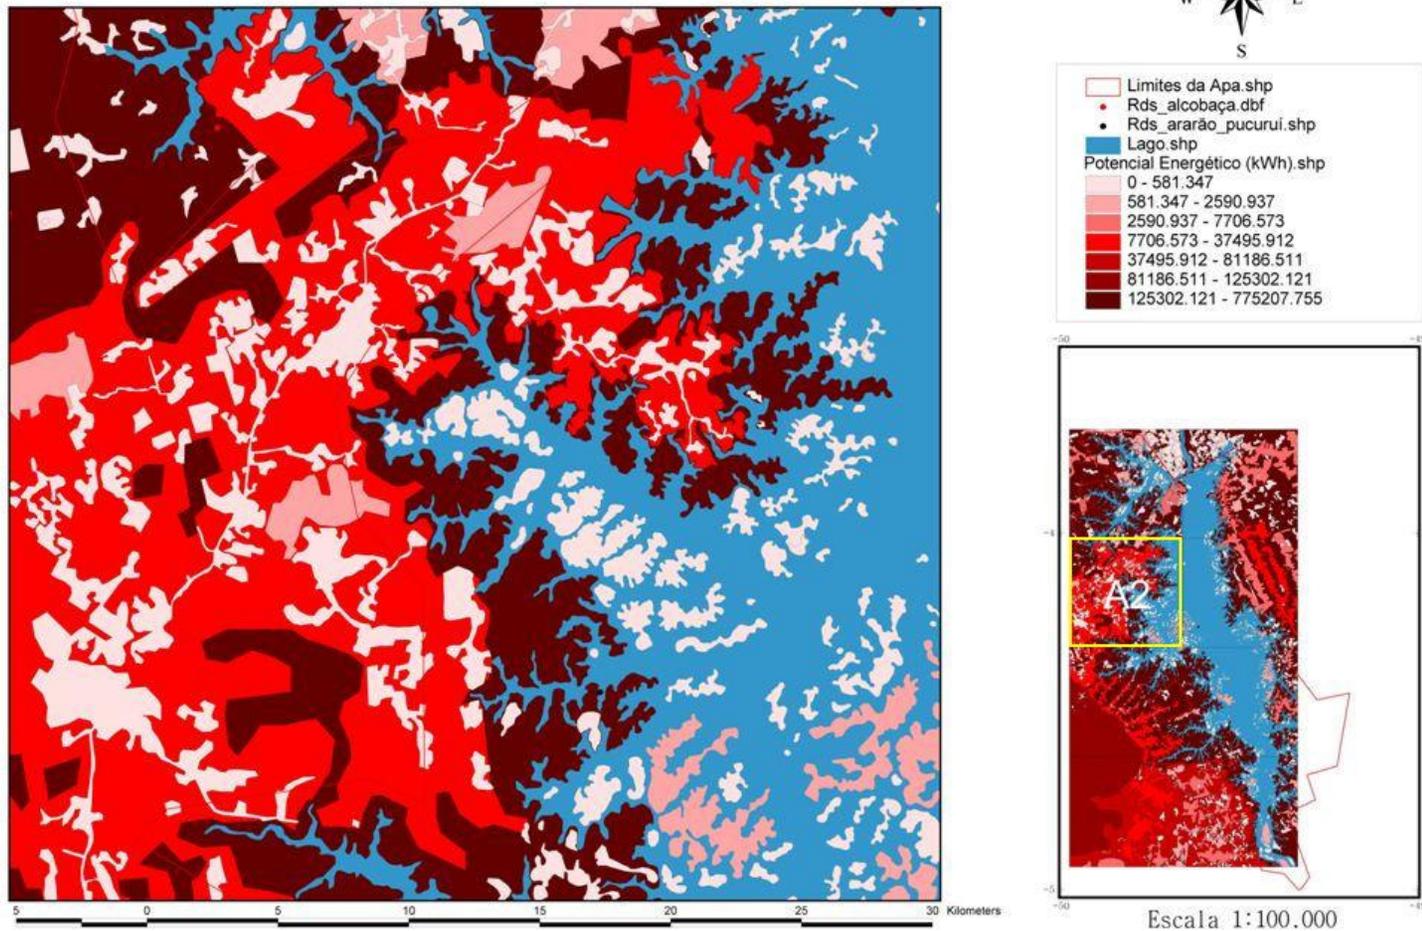


Figura 48 - Mapa A2 (2 de 8) mostrando volume estimado de potencial energético

TUCURUÍ - Potencial Energético (kWh)

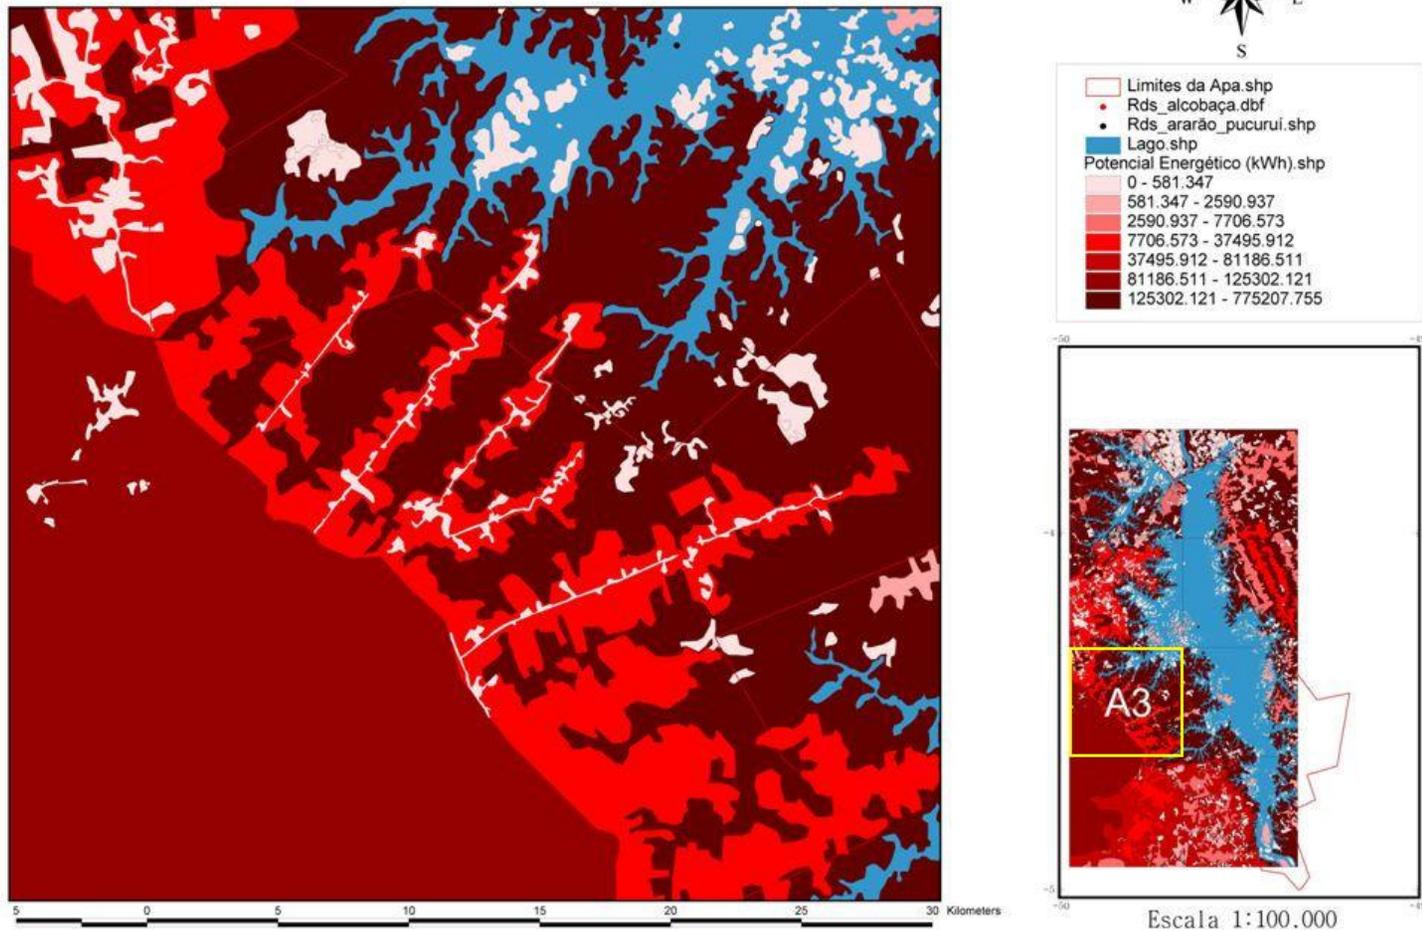


Figura 49 - Mapa A3 (3 de 8) mostrando volume estimado de potencial energético

TUCURUÍ - Potencial Energético (kWh)

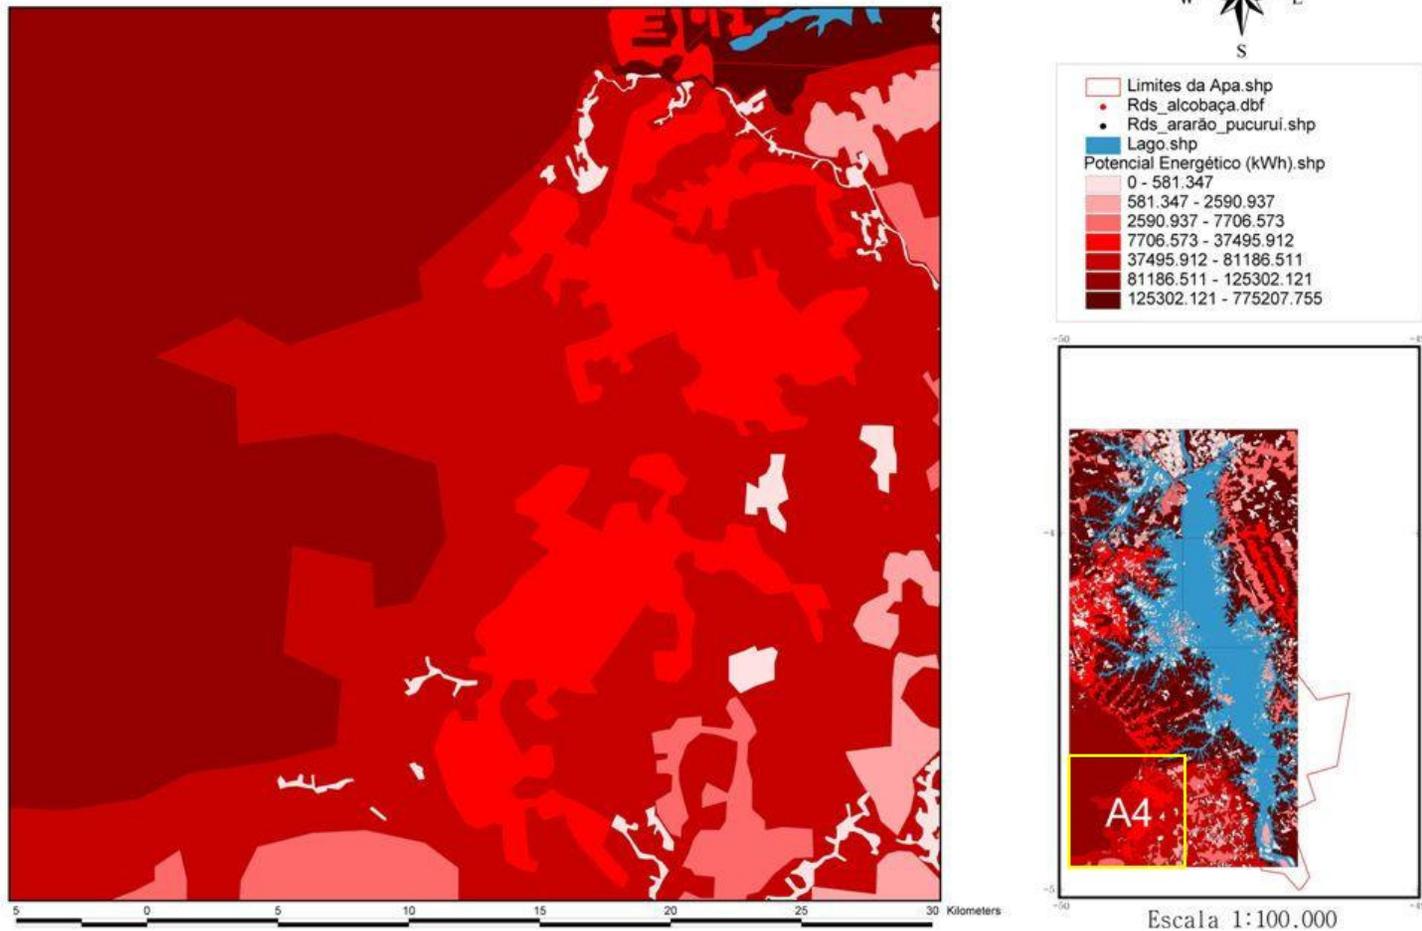


Figura 50 - Mapa A4 (4 de 8) mostrando volume estimado de potencial energético

TUCURUÍ - Potencial Energético (kWh)

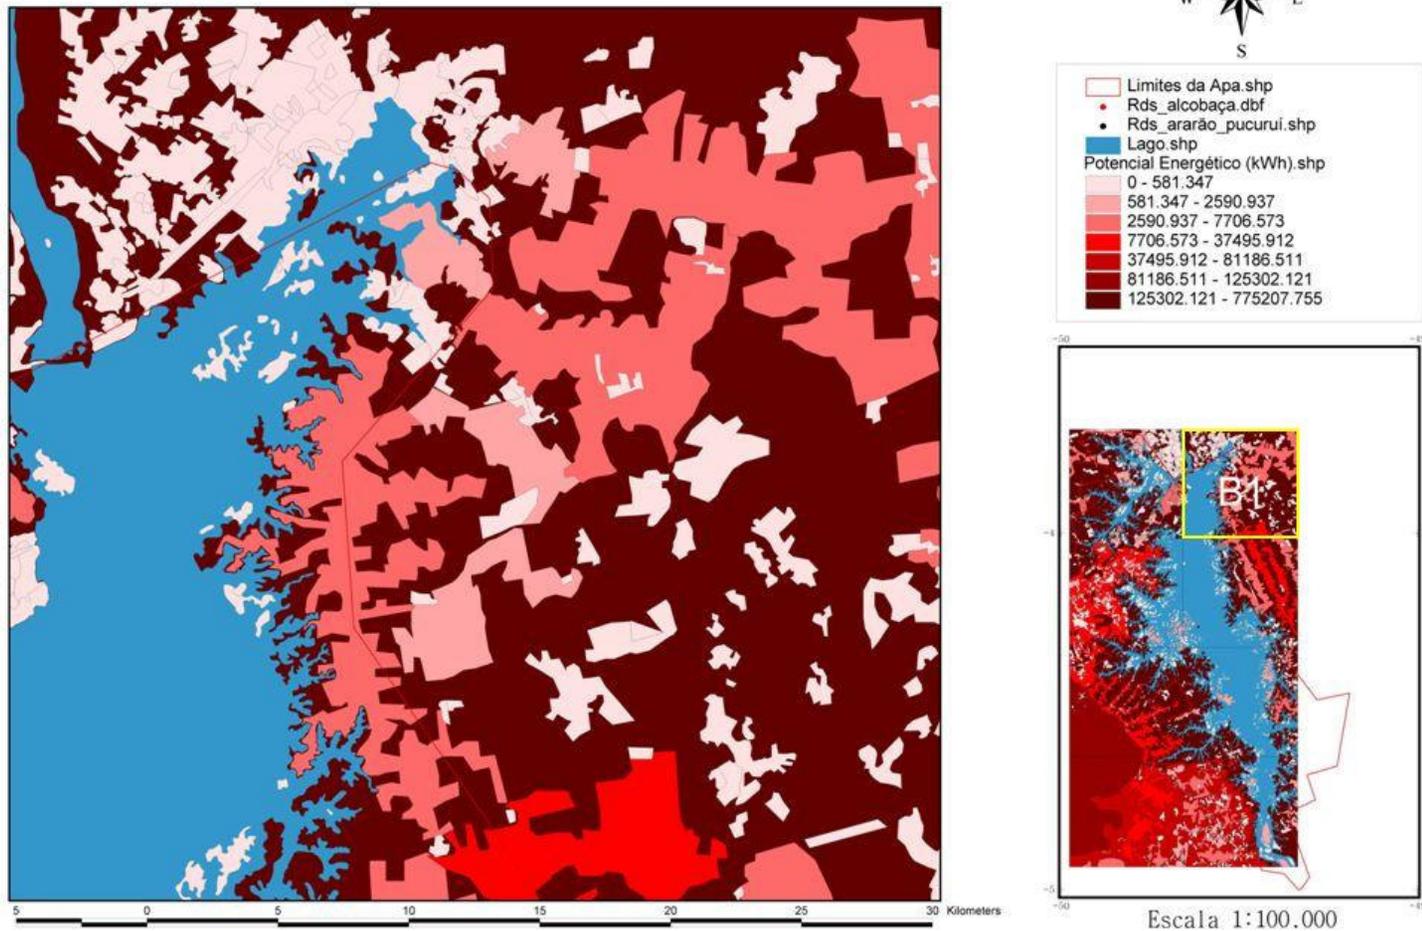


Figura 51 - Mapa B1 (5 de 8) mostrando volume estimado de potencial energético

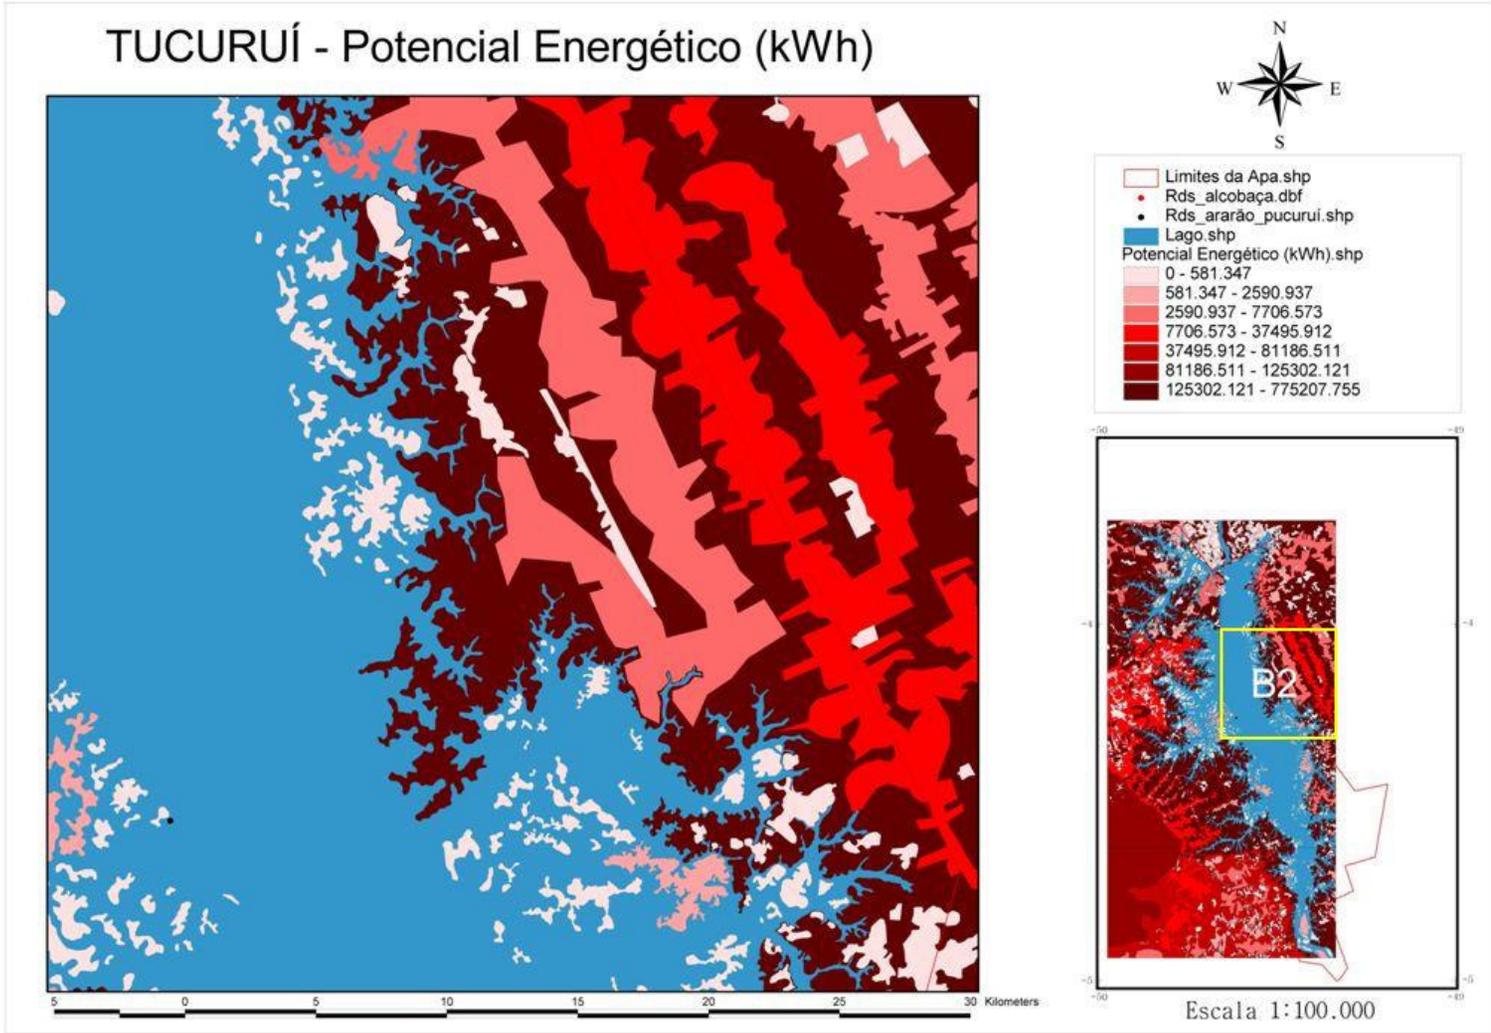


Figura 52 - Mapa B2 (6 de 8) mostrando volume estimado de potencial energético

TUCURUÍ - Potencial Energético (kWh)

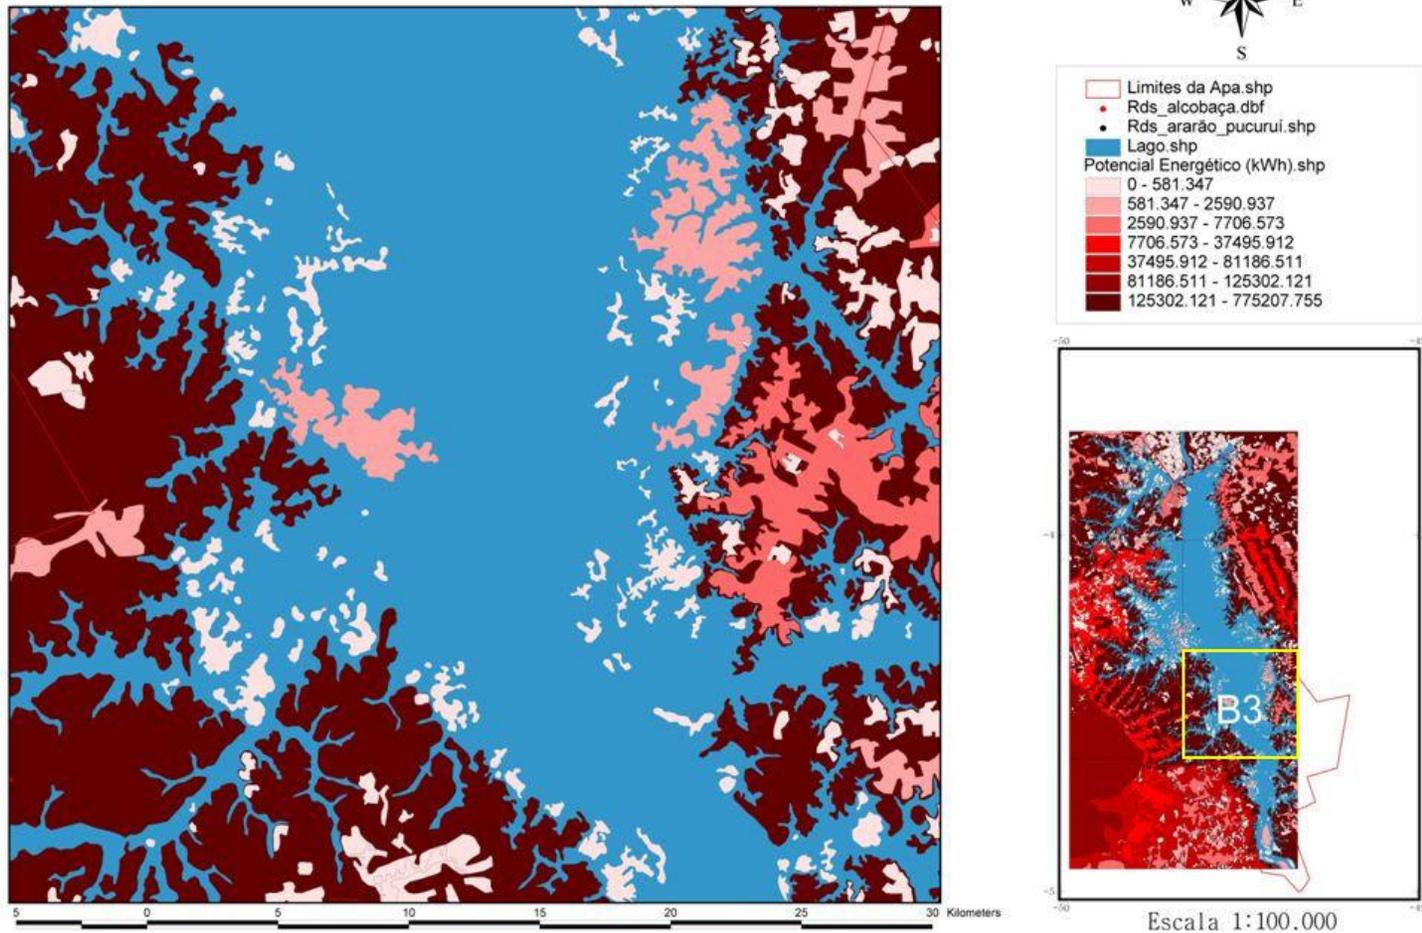


Figura 53 - Mapa B3 (7 de 8) mostrando volume estimado de potencial energético

TUCURUÍ - Potencial Energético (kWh)

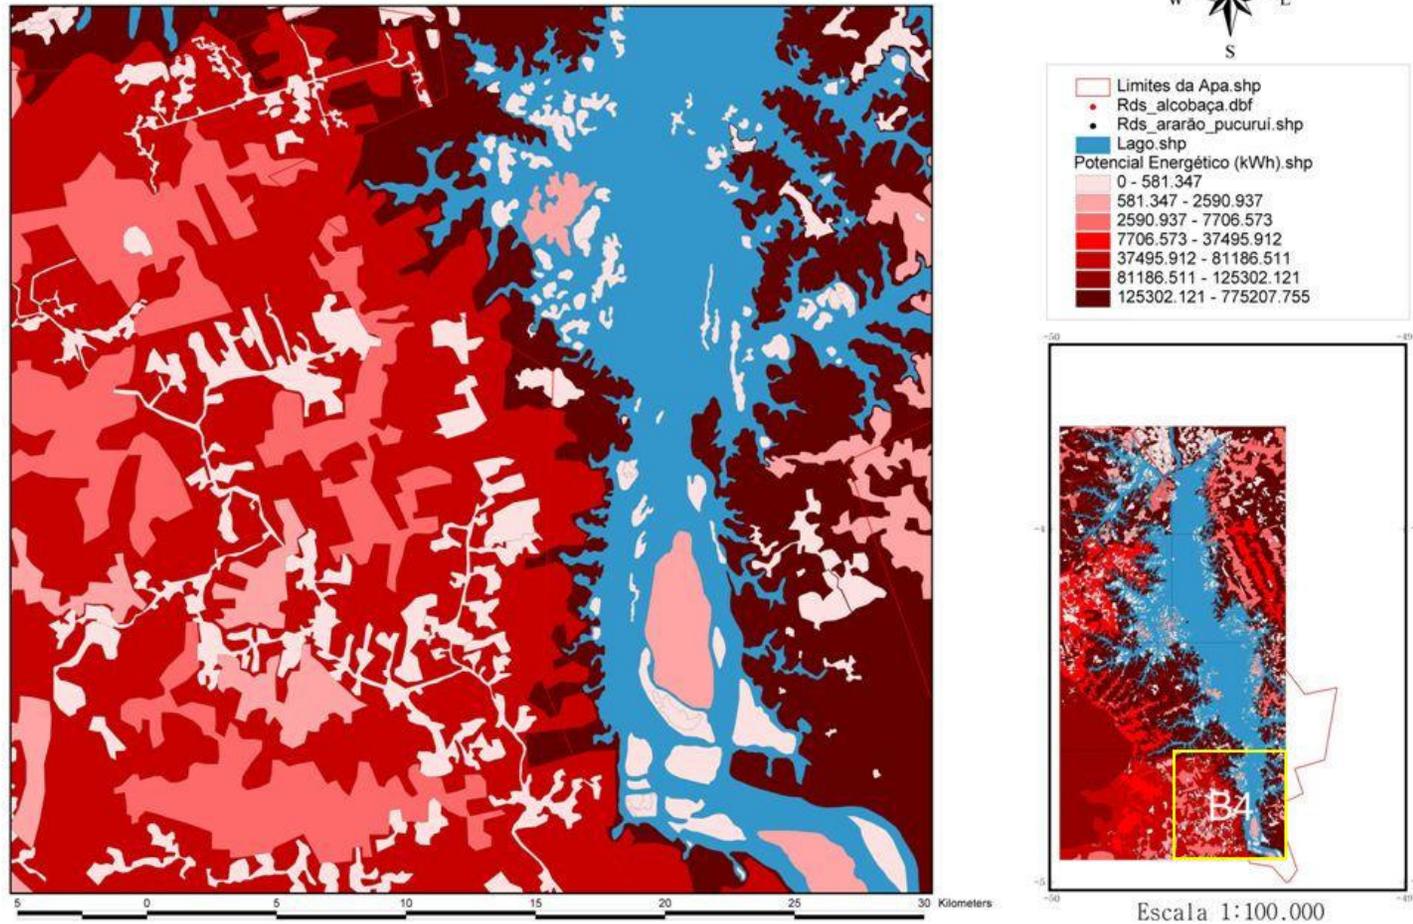


Figura 54 - Mapa B4 (8 de 8) mostrando volume estimado de potencial energético