

# Estimation of Above-ground Forest Biomass in Amazonia with Neural Networks and Remote Sensing

A. C. Almeida, P. L. C. Barros, J. H. A. Monteiro, B. R. P. Rocha

**Abstract**— This paper proposes an integrated methodology for estimating aboveground forest biomass in Amazon region. It is based on remote sensing, artificial neural networks and geographical information systems technologies for achieving confident results with a lesser cost than traditional methods of forest inventory. This methodology was tested and validated in Tucuruí Reservoir, Brazil.

**Keywords**— biomass estimation, neural networks, remote sensing.

## I. NOMENCLATURA

ELETRONORTE – Centrais Elétricas do Norte do Brasil.  
MEAPA – Metodologias Integradas para o Mapeamento de Energias Alternativas no Estado do Pará. SIG – Sistemas de Informações Geográficas, NDVI – Normalized Difference Vegetation Index.

## II. INTRODUÇÃO

Em 1996, uma parceria formada por alguns países da Europa, incluindo Portugal, decidiu investir em um sistema informatizado de planejamento energético com fontes renováveis de energia, em escala regional, que levasse em conta a abundância, localização geográfica, tecnologia disponível e custos de recursos eólicos e solares. Essencialmente, esse sistema consistia de dois componentes: o primeiro fazia uma avaliação técnica e econômica das possibilidades de eletrificação rural da área em estudo e o segundo cuidava de criar cenários para a decisão, baseados em informações geográficas. Dessa forma, o componente formado por um Sistema de Informações Geográficas (SIG) era a grande novidade, que permitiu ao sistema fornecer um tratamento diferenciado, local e geograficamente integrado das informações. Esse sistema informatizado ficou conhecido como Projeto SOLARGIS.

Baseado no sucesso desse sistema, em 1998, um convênio foi firmado pela Universidade Federal do Pará, Brasil, (UFPA), 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. Como o SOLARGIS só cuidava das fontes eólicas e solares, foi desenvolvido um módulo de processamento que incluísse a biomassa, dada a importância dessa fonte renovável de energia na região a ser estudada. Dessa forma, surgiu o projeto Metodologias Integradas para o Mapeamento de Energias Alternativas no Estado do Pará (MEAPA).

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 nas áreas isoladas da região, desenvolver metodologias integradas para dimensionamento e avaliação de soluções de eletrificação rural, implementar a metodologia em aplicações SIG, mapear os recursos energéticos renováveis, no Arquipélago do Marajó e realizar testes da metodologia na região de estudo.

Com base nos resultados desse trabalho, [1] estudou a sustentabilidade energética do Marajó, com relação ao uso de fontes renováveis de energia, incluindo solar, eólica e biomassa, concluindo pela viabilidade do uso de biomassa como combustível primário para fornecimento de energia elétrica para populações isoladas do Arquipélago. Concluiu ainda, que haveria diminuição de emissão de CO<sub>2</sub>, dada a substituição que ocorreria de equipamentos como gaseificadores usando biomassa em lugar de geradores diesel em uso atualmente em algumas dessas localidades.

Em vista disso, seria interessante que essa aplicação pudesse ser utilizada em outras áreas da região amazônica. Ocorre, entretanto, que um inventário florestal para se obter o potencial de biomassa na região amazônica é caro, com preços de mercado por volta de US\$ 5 (cinco dólares) por hectare para grandes áreas, como o Marajó. Além do custo financeiro, a região, por suas características geográficas, de florestas e grandes rios, oferece dificuldades e obstáculos imensos à realização de um levantamento desse porte.

Portanto, acredita-se que apresenta interesse econômico e científico a pesquisa de um método alternativo para a aquisição de potencial bioenergético da floresta, que possa fornecer resultados equivalentes a um custo menor e,

Arthur da Costa Almeida, Univ. Federal do Pará – UFPA, Brasil,  
[arthur@ufpa.br](mailto:arthur@ufpa.br)

Paulo Luiz Contente Barros, Univ. Federal Rural da Amazonia – UFRA,  
Brasil.

[paulo.contente@ufra.edu.br](mailto:paulo.contente@ufra.edu.br)

José Humberto Araujo Monteiro, Univ. Federal do Pará,

[jhumberto01@yahoo.com.br](mailto:jhumberto01@yahoo.com.br)

Brigida Ramati Pereira da Rocha, Univ. Federal do Pará, Brasil,  
[brigida@ufpa.br](mailto:brigida@ufpa.br)

principalmente, que seja mais cômodo de ser utilizado na escala e nas condições geográficas da região amazônica.

É o objetivo deste trabalho, propor uma metodologia integrada para estimativa de potencial energético de biomassa florestal na região amazônica, que utiliza tecnologia de redes neurais artificiais para extrair informações sobre biomassa a partir de imagens de satélite e inseri-las em uma aplicação desenvolvida em sistemas de informações geográficas.

Espera-se que essa metodologia seja de interesse para as áreas de engenharia elétrica, engenharia florestal e para aquelas que cuidam do meio ambiente.

Espera-se também, que esse sistema informatizado de planejamento energético com fontes renováveis de energia tenha uma utilização maior e possa contribuir para projetos de eletrificação rural de comunidades isoladas da Amazônia.

### III. METODOLOGIA INTEGRADA.

#### A. Trabalhos relacionados

O melhor método 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 medir-se o volume de biomassa a partir de dados de sensoriamento remoto tem atraído muita pesquisa nessa área, especialmente pela 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 [2], 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 múltipla, pois elas utilizam toda a informação eletromagnética capturada pelos sensores. Entretanto, 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. Entretanto, tem-se 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 [2].

No Brasil, Nishida e Bastos [3] 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 [4] escreveram sobre o uso de técnicas de classificação de cobertura vegetal em imagens de LANDSAT usando redes neurais artificiais, comparando treinamento supervisionado e não-supervisionado na obtenção de resultados.

Jensen et al. [5] usaram imagens do LANDSAT e índices de vegetação, como o NDVI, 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.

Del Frate e Solimini [6] [7] 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..

Saatchi et al. [8] 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. [9] [10] 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.

Neste trabalho, o ponto central é utilizar redes neurais para 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.

#### B. Redes Neurais Artificiais

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 natural. Elas são dispositivos não-lineares, com processamento paralelo, matematicamente funcionando como

aproximadores universais de funções [11].

Conforme [12], diferentes arquiteturas de redes neurais existem em função de suas diversas finalidades. Quanto ao tipo de treinamento, 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 da discrepância, 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.

Segundo [2], [6], 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.

#### (1) Redes de Kohonen

O Mapa Auto-Organizável (SOM – Self Organizing Map) de Kohonen é uma rede neural artificial (RNA) com duas camadas, de treinamento não-supervisionado, entrada intervalar e conexão competitiva [11]. 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.

Descobriu-se que o córtex cerebral humano aloca regiões específicas para atividades específicas e que, para uma determinada ativação cerebral, o grau de ativação dos neurônios diminuiu à medida que se aumentava a distância da região de ativação inicial [13].

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.

#### (2) Redes RBF (Funções de Base Radial)

As redes RBF possuem, além das camadas de entrada e de saída uma única camada oculta, com neurônios possuindo funções de base radial como a gaussiana [6]. 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 [14].

Segundo [14], o problema de interpolação de uma hiper-superfície em um espaço multidimensional pode ser interpretado da seguinte forma:

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

de interpolação  $F(x_i) = y_i$  com  $i = 1, 2, \dots, N$ .

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

$$F(x) = \sum_1^N c_i h(\|x - x_i\|) + \sum_1^m d_i p_i(x), \quad m \leq N \quad (1.1)$$

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

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 [14]. Generalizar é equivalente ao uso dessa superfície para encontrar os dados de saída 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 [11].

#### C. 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.
- (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 e o valor do NDVI em cada ponto e do volume de biomassa, derivado do inventário florestal. As etapas a, b e c serão feitas com programa codificado no ambiente de redes neurais do MATLAB.
- (c) Estimar o potencial de biomassa de toda a região de estudo. 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).
- (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.
- (e) Criar o banco de dados geográfico de volume biomassa da região, incluindo mapa vetorial e tabela de valores no programa ARCVIEW.

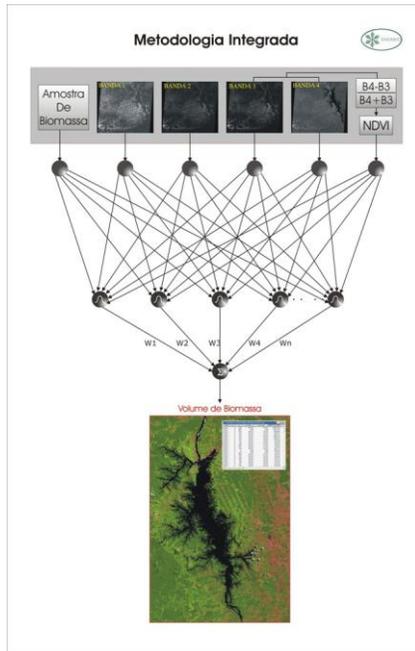


Fig. 1. Esquema demonstrativo da metodologia utilizada.

#### D. Criação dos Dados de Entrada

A região estudada 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° 59' W, abrangendo uma área de 9.633 km<sup>2</sup>, aproximadamente 963.000 ha.

As imagens utilizadas são do satélite LANDSAT, com resolução nominal de 30m.



Fig. 2. Área de estudo: entorno do Lago de Tucuruí, Brasil.

Para a segmentação e classificação das imagens foram usadas redes neurais de Kohonen, com sete classes, relacionadas com as diversas tipologias florísticas encontradas na região, por serem consideradas superiores às técnicas estatísticas, tais como a apresentada em [15]. Para a aproximação do mapeamento funcional entre os dados de entrada e o volume de biomassa, foi usada uma rede neural com arquitetura RBF, 5-65-1. Os programas foram desenvolvidos na linguagem de programação do software

MATLAB.

A integração dos dados com a base geográfica digitalizada, depois de classificada em padrões de cobertura de vegetação e volume de biomassa [4], [16], foi feita no Sistema de Informações Geográficas ARCVIEW, usando-se a linguagem de programação AVENUE e também no SPRING [17].

Setenta e duas (72) áreas, cada uma medindo 10m x 200m, foram selecionadas como locais de inventário florestal, para funcionarem como áreas de treinamento da rede e validação da metodologia. Essas áreas foram escolhidas em função da representatividade das diversas tipologias florísticas existentes na região em estudo. Além dessas áreas, 10 outras áreas menores foram também escolhidas, como exemplos de áreas que sofreram processo de ocupação humana na região.

Em seguida, cada uma dessas coordenadas foi localizada na imagem de satélite do LANDSAT, com ajuda do software SPRING, e extraídos os DN (*Digital Numbers*) relacionados com as bandas 1, 2, 3 e 4, em blocos de matrizes de 5x5 pixels, conforme mostrados pelo programa.

As planilhas de dados são formadas pelas colunas contendo as coordenadas da região, os valores de 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

$$NDVI = \frac{IVP - VER}{IVP + VER} \quad (1.2)$$

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

## IV. RESULTADOS E DISCUSSÃO

### A Estimativa do Potencial de Biomassa

Comparando-se os resultados estimados pela rede e os dados obtidos em campo, obteve-se um erro médio quadrático (RMS) de 2,343 e um coeficiente de correlação de 0,81.

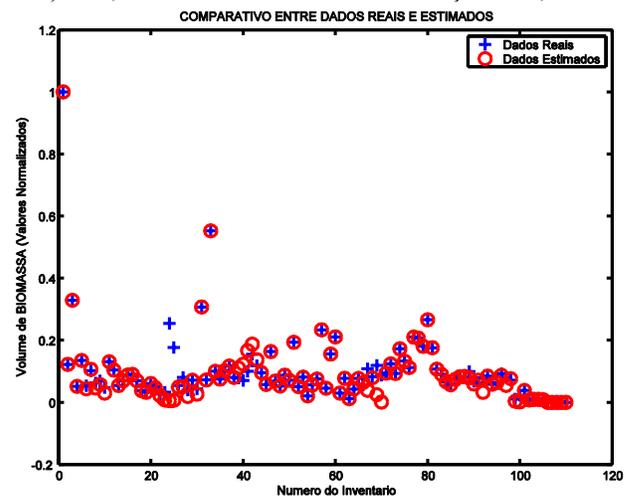


Fig. 3. Comparativo entre dados reais e estimados de volume de biomassa.

A Fig. 3 mostra os dados estimados e os dados reais de volume de biomassa, para cada entrada na planilha de dados. Os dados reais estão representados por uma “+” e os dados estimados pela rede neural estão simbolizados por “o”.

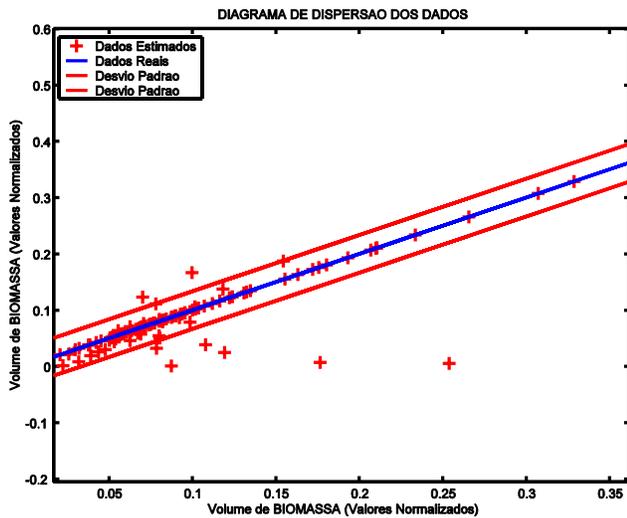


Fig. 4. Diagrama de dispersão dos dados estimados e reais.

A Fig. 4 mostra os resultados estatísticos da correlação entre os dados estimados e os dados reais. Pelos valores obtidos de RMS e  $R^2$ , citados anteriormente, verifica-se que os resultados possuem uma confiabilidade aceitável para um trabalho dessa escala.

Os resultados obtidos foram introduzidos em um SIG, na forma de tabela de dados no formato DBF, e a partir daí, foram obtidos mapas, como os da Fig. 5, mostrando a distribuição da quantidade de biomassa, em  $m^3/ha$  em cada região do entorno do Lago de Tucuruí.

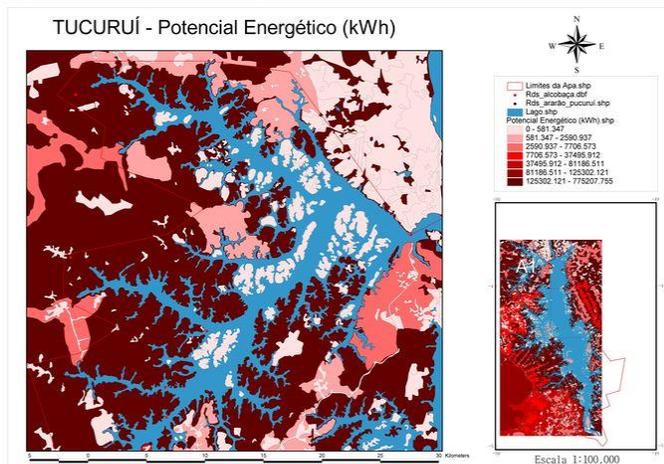


Fig. 5. Potencial energético estimado (em kWh), em uma região do entorno do Lago de Tucuruí, Brasil.

### B Discussão.

As dificuldades técnicas advindas da estimativa de volume de biomassa através de imagens de sensoriamento remoto, sejam de satélite ou radar são conhecidas e bastante discutidas na literatura, ver [2], [10].

Grande número de pesquisadores tem se valido de técnicas de regressão simples e múltipla, para derivar os dados de biomassa em grandes áreas [18], [19]. Entretanto, observou-se que as redes neurais artificiais têm se mostrado superior às técnicas que utilizam métodos de regressão, conforme [2], [12].

Neste trabalho, foram adotados dois tipos de redes neurais: uma, a rede de Kohonen, para dar homogeneidade média aos agrupamentos arbóreos da região, e outra, a rede RBF, para fazer a aproximação funcional do mapeamento entre os níveis de refletância de energia eletromagnética e os volumes de biomassa observados em campo.

Além disso, o grande número de dados coletados em campo, através do inventário florestal, contribuiu de forma decisiva para um treinamento eficiente da rede neural, facilitando a obtenção de dados mais confiáveis.

Uma vez feita a estimativa dos volumes, a imagem com os valores estimados foi classificada pela rede de Kohonen, para que as áreas com valores semelhantes de volume de biomassa fossem agrupadas, obtendo-se assim um valor médio de volume na área, conforme pode ser visto na Fig. 5.

A técnica de normalização dos dados, sugerida por vários autores, inclusive [20], e adotada neste trabalho, em muito contribuiu para acelerar o treinamento da rede RBF usada.

A rede RBF se mostrou adequada para esse tipo de aproximação funcional de um mapeamento de uma função contínua de um espaço multidimensional em um escalar, o volume.

### V. CONCLUSÕES

Fazer esse levantamento por terra, na região amazônica, é uma tarefa cara, demorada e bastante difícil. Em preços de mercado, o custo por hectare, para se fazer um inventário numa região como o entorno do Reservatório de Tucuruí, é de US\$ 14 (quatorze dólares) por hectare, para áreas menores que 250 hectares e de US\$ 5 (cinco dólares) para áreas maiores. Neste caso a área de estudo compreende 1 milhão de hectares, o que dá um custo total de US\$ 5 milhões de dólares.

O uso desta metodologia permitiu reduzir este custo para US\$ 250000 (duzentos e cinquenta mil dólares), com um considerável ganho de escala.

Para além da sua utilização em planejamento energético com biomassa, principalmente para comunidades isoladas da Amazônia, essa metodologia vislumbra outras importantes aplicações, tais como inventários florestais e identificação seletiva de tipologias florísticas, como dendê, para avaliação da produção de óleo, por exemplo.

A principal desvantagem desta metodologia é que ela ainda precisará de dados obtidos em campo para fornecer resultados confiáveis em uma região diversa daquela para a qual seu treinamento foi estabelecido. Entretanto, o custo para a obtenção desses dados será muito inferior ao custo oriundo dos procedimentos clássicos de inventário florestal.

### AGRADECIMENTOS

A toda a equipe de engenheiros e técnicos da Universidade Federal Rural da Amazônia (UFRA), em particular, ao Vice-Reitor, Prof. Dr. Suelo Numazawa, pelo estafante trabalho de inventário florestal realizado na área de estudo.

## REFERÊNCIAS

- [1] I. M. O. Silva, Estudo da Sustentabilidade de Energias Renováveis no Marajó. Tese de Doutorado. UFPA, Belém, 2003.
- [2] P. Bettinger, R. Hayashi. "Estimation of Aboveground Biomass with Remotely Sensed Imagery: A Brief Literature Review". *Center for Forest Business. Research Note 25*. University of Georgia, 2006.
- [3] W. Nishida; L. C. Bastos; "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*.
- [4] A. Venturieri. J. R. Santos; "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.
- [5] J. R. Jensen; F. Qiu; M. Ji; "Predictive Modeling of Coniferous Forest Age Using Statistical and Artificial Neural Networks Approaches to Remote Sensor Data". *International Journal of Remote Sensing*. 20, 1999.
- [6] F. Frate; D. Solimini; "On the Retrieval of Forest Biomass from SAR Data by Neural Networks". *Proc. IEEE, Ed. IEEE*, 2003.
- [7] F. Frate; D. Solimini; "On Neural Networks Algorithms for Retrieving Forest Biomass from SAR Data". *IEEE Transactions on Geoscience and Remote Sensing*. Vol. 42, 2004.
- [8] S. S. Saatchi; R. A. Houghton; R. C. S. Alvala; J. V. Soares; Y. Yo; "Distribution of Aboveground Live Biomass in the Amazon Basin". *Global Change Biology*, 2006.
- [9] D. Lu; P. Mause; E. Brondizio; E. Moran. "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.
- [10] D. Lu; "The Potential and Challenge of Remote-sensing Based Biomass Estimation". *International Journal of Remote Sensing*, 27, 2006.
- [11] S. Haykin, *Redes Neurais, Princípios e Prática*. Ed. Bookman, Porto Alegre, 2001.
- [12] M. Egmont-Petersen, D. Ridder, H. Handels,. "Image processing with neural networks – a review". *Pattern Recognition*, vol 35, pp 2279-2301, Ed. Pergamon, 2002.
- [13] T. Kohonen, "The Self Organizing Map". *Proceedings IEEE*, vol 78, no 9, pp 1464-1480, Ed. IEEE, 1990..
- [14] T. Poggio, F. Girosi, "Networks for approximation and learning". *Proceedings IEEE*, vol 78, no 9, pp 1481-1497, Ed. IEEE, 1990.
- [15] A. Conci, E. O. Nunes, "Texture Segmentation and Edge Location of Regions in Multiband Images", *IEEE Latin America Transactions*, Vol. 5, No. 3, pp. 185-192, June 2007.
- [16] C.M Bishop; *Neural Networks for Pattern Recognition*. Oxford University Press. Oxford, 1995.
- [17] G. Câmara, R.C. M Freitas, "SPRING: Integrating remote sensing and GIS by object-oriented data modelling". *Journal of Computer & Graphics*. 20(3) 395-403, 1996.
- [18] C. L. Sousa Uso de Imagens-índice e de Imagens-proporção para avaliar quantidade de madeira em povoamentos de pinus spp. (Dissertação de Mestrado). INPE, 1997.
- [19] D. Zhieng, J. Rademacher, J. Chen, T. Crow, M. Bresee, J. Le Moine, S. Ryu, 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.
- [20] S. S. Panda, V. Garg, I. Chaubey. Artificial Neural Networks Application in Lake Water Quality Estimation Using Satellite Imagery. *Journal of Environment Informatics*. V. 4, 2004.



**Arthur da Costa Almeida** é graduado e mestre em Matemática, pela Universidade Federal do Pará (UFPA). Trabalhou durante vários anos na área de informática de uma concessionária de energia elétrica, desenvolvendo sistemas da área comercial e de engenharia. Em 1998, ingressou como professor de Matemática Aplicada, na UFPA. Atualmente cursa o doutorado em Engenharia Elétrica, onde tem pesquisado aplicações de redes neurais na área de planejamento energético com biomassa na Amazônia.



**Paulo Luiz Contente de Barros** possui graduação em Engenharia Florestal pela Faculdade de Ciências Agrárias do Pará (1975), mestrado em Ciências Florestais pela Universidade Federal do Paraná (1980) e doutorado em Recursos Florestais e Engenharia Florestal pela Universidade Federal do Paraná (1986). Atualmente é Professor Adjunto da Universidade Federal Rural da Amazônia (UFRA). Possui diversos trabalhos publicados em periódicos da área de Engenharia Florestal.



**José Humberto Araújo Monteiro**, possui graduação em Engenharia Elétrica pela Universidade Federal do Pará (2005) e é aluno do Mestrado em Engenharia Elétrica da mesma Universidade. Tem participado de pesquisas na área de planejamento energético com biomassa na Amazônia e publicado diversos trabalhos em congressos.



**Brígida Ramati Pereira da Rocha** possui graduação em Engenharia Elétrica (1976), mestrado em Geofísica (1979) e doutorado em Geofísica pela Universidade Federal do Pará (1995). É Professor adjunto IV da Universidade Federal do Pará. Tem experiência na área de Engenharia Elétrica, atuando principalmente nos seguintes temas: propriedades elétricas de rochas, fractais, métodos eletromagnéticos, prospecção geofísica, proteção. Atualmente tem participado de diversos projetos de planejamento energético com biomassa para eletrificação de comunidades isoladas da Amazônia.