

Uso de redes neurais artificiais como uma alternativa para mapeamento de biomassa e carbono orgânico no componente arbóreo de florestas naturais

Artificial neural net use as an alternative to biomass and organic carbon mapping in natural forest trees

Emerson Roberto Schoeninger¹
Henrique Soares Koehler²
Luciano Farinha Watzlawick³
Paulo Costa de Oliveira Filho⁴

Resumo

O problema do aquecimento global tornou-se preocupação internacional, culminando com a ratificação do Protocolo de Kioto. Neste documento, constam as definições e os objetivos dos Mecanismos de Desenvolvimento Limpo e tem em seu escopo definidos procedimentos flexibilizadores, para tornar mais fácil aos países industrializados compensar em conjunto suas emissões poluentes. Sem esses mecanismos, as nações industrializadas teriam grande dificuldade em compensar emissões poluentes por meio de medidas tomadas isoladamente. Um dos mecanismos criados é o mercado de crédito de carbono, onde investidores compensam as emissões de gases poluentes pela compra dos créditos de carbono. Para que isso seja possível é necessário que sejam realizados estudos e levantamentos, que compreendem desde a quantificação das emissões até às quantidades de carbono acumuladas de diferentes formas. Por tal, o desenvolvimento de metodologias para estimar o carbono orgânico armazenado em florestas tem despertado interesse de vários pesquisadores, que aplicam as mais variadas formas de estimativas, desde quantificações diretas em campo até a obtenção de estimativas pelo uso de equações de regressão aplicadas em imagens de satélite, visando

-
- 1 Dr.; Engenheiro Florestal; Klabin Florestal-SC; e-mail: erschoeninger@ibest.com.br
 - 2 Dr.; Engenheiro Florestal; Professor do Departamento de Fitotecnia e Fitossanitarismo da Universidade Federal do Paraná; E-mail: koehler@ufpr.br
 - 3 Dr.; Engenheiro Florestal; Professor do Departamento de Agronomia da Universidade Estadual do Centro-Oeste; Bolsista de Produtividade em Pesquisa do CNPq; E-mail: Luciano.watzlawick@pq.cnpq.br
 - 4 Dr.; Engenheiro Florestal; Professor do Departamento de Engenharia Ambiental da Universidade Estadual do Centro-Oeste; E-mail: paulocostafh@irati.unicentro.br

Recebido para publicação em 14/11/2006 e aceito em 30/11/2007

Ambiência Guarapuava, PR v.4 n.3 p.529 - 549 Set./Dez. 2008 ISSN 1808 - 0251

mapear essa variável de forma expedita e rápida. Recentemente um novo procedimento, pertencente à área da chamada Inteligência Artificial (IA), tem sido aplicado para mapeamento do uso do solo por meio de classificação digital utilizando Redes Neurais Artificiais (RNA). O propósito do presente artigo é mostrar a viabilidade do uso de RNA como alternativa para o mapeamento de biomassa e carbono em grandes extensões florestais.

Palavras-chave: sensoriamento remoto; redes neurais; quantificação de carbono.

Abstract

The global warming problem has become an international issue, culminating with the ratification of the Kyoto Protocol. This document presents the definitions and objectives of the Clean Development Mechanisms, with recommendations of flexible procedures that facilitate the compensation of the pollution emissions in industrialized countries. Without these mechanisms the industrialized countries alone would have great difficulties to mitigate their pollution emissions. One of the forms to implement these procedures is the carbon credits market, where potential polluters would compensate their emission of polluting components by buying carbon credits. In order to make this possible, studies and assessments of carbon emissions and storage in different ways have to be done. The development of methodologies to estimate the amount of organic carbon stored in forests has appealed to many researchers, who have been applying several forms of estimating biomass and carbon content, varying from direct field measurements to the use of regression equations applied to satellite images, focusing on the fast mapping of this variable. Recently a new procedure, belonging to the Artificial Intelligence field, has been applied to the mapping of soil use by means of digital classification with the Artificial Neural Nets (ANN). The objective of the present paper is to show the viability of using ANN as an alternative for mapping biomass and carbon content in large forest areas.

Key words: remote sensing; artificial neural nets; biomass; carbon; quantification.

Introdução

Tratando-se de tema atual, o acúmulo de carbono na atmosfera, oriundo da queima de combustíveis

fósseis ou de queimadas da vegetação, é um dos principais responsáveis pelo aumento da temperatura na terra que tem, por consequência, um aumento do nível dos mares e uma variação dos

eventos climáticos. Uma alternativa viável para amenizar o agravamento desse processo, que pode colocar em risco a vida na terra, consiste no armazenamento do carbono atmosférico pelas florestas (RENNER, 2004).

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

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

A preocupação com relação à intensificação dos eventos climáticos atípicos tem gerado a possibilidade de captação de recursos financeiros advindo dos países do Anexo I do Protocolo de Kioto (países desenvolvidos), que é composto por países que possuem

economias fortes e altos indicadores sociais, tais como qualidade de vida dos seus habitantes (WIKIPÉDIA, 2006).

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

Para que a captação de recursos financeiros seja possível, trabalhos de quantificação e mapeamento de biomassa e carbono, utilizando diferentes abordagens, são necessários. Contudo, ainda não existem registros de pesquisas que integrem dados de diferentes escalas e fontes, como inventários florestais e imagens satélites, para a obtenção de mapas de distribuição de dados biofísicos para florestas naturais.

A utilização de Redes Neurais Artificiais (RNA), que são um conjunto de técnicas não paramétricas, pode ser utilizada como método alternativo para o mapeamento de padrões de entrada e padrões de saída (classes) associados, com o uso de um conjunto de pares de treinamento (TODT, 1998). Diante ao exposto, o presente artigo tem por objetivo demonstrar o potencial de utilização de

RNA para o mapeamento de biomassa e carbono orgânico arbóreo estimado.

Sensoriamento Remoto em Mapeamento de Vegetação

Sensoriamento Remoto (SR) pode ser definido como a ciência e a arte de se obter informações sobre um determinado objeto, área ou fenômeno, por meio de dados coletados por um equipamento que não entra em contato direto com o objeto, área ou fenômeno estudado (CREPANI, 1993). A diversidade de aplicações do SR faz com que um número cada vez maior de pesquisadores de diferentes áreas do conhecimento utilize essa ferramenta. Uma das principais vantagens dessa técnica com relação aos estudos ambientais é que ela permite a análise de grandes áreas em apenas uma imagem, em imageamentos contínuos e em intervalos regulares, levando à obtenção de dados multiespectrais, multitemporais em diferentes resoluções espaciais (KOFFER, 1992).

O sinal registrado pelo sensor é dependente das características espectrais da superfície observada. O comportamento espectral de um determinado objeto está relacionado com suas propriedades de reflectância da radiação eletromagnética (AFFONSO, 2004). A radiação eletromagnética (REM) é constituída de várias formas, sendo as radiações da faixa do visível apenas algumas delas. As ondas de rádio, radiações termiais, raios X, ultravioletas, infravermelho, cósmicos são outras formas de REM e, o conjunto de diferentes tipos de comprimento de onda de REM, denomina-se espectro eletromagnético (AVERY

e BERLIN, 1992). Quando o alvo de interesse é a vegetação, as folhas são os elementos que mais contribuem para o sinal detectado pelos sensores, e suas características morfológicas e bioquímicas determinam quais comprimentos de ondas serão absorvidos, refletidos ou transmitidos (JACKSON e HUETE, 1991).

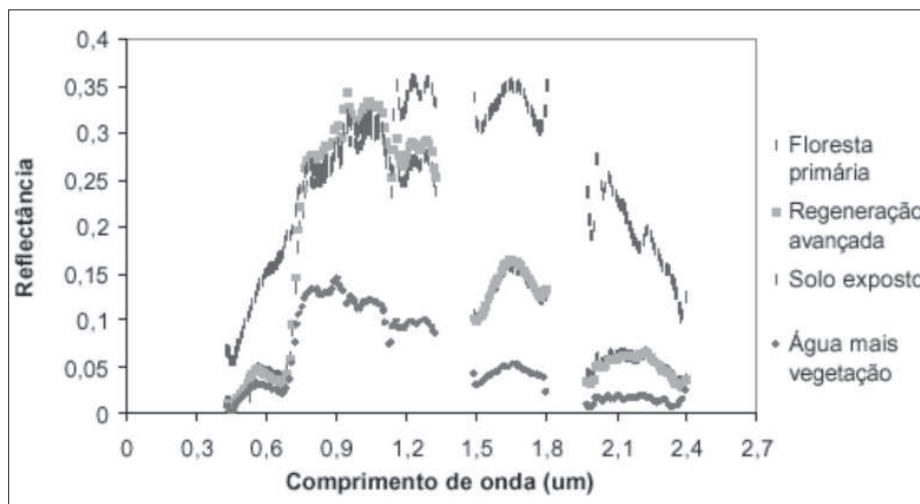
Os principais aspectos relacionados com o comportamento espectral de uma folha verde sadia nos comprimentos de onda do visível (0,4 - 0,7 μ m), no infravermelho próximo (0,7 - 1,3 μ m) e no infravermelho médio (1,3 - 3,0 μ m) são definidos por vários fatores. O comportamento espectral da vegetação está relacionado com a presença de pigmentos, de água e pela estrutura do mesófilo das folhas (GATES, 1980). Na região do visível, a maior parte da radiação incidente é absorvida pelos pigmentos presentes nas folhas (clorofila a e b, caroteno e xantofilas), encontrados nos cloroplastos que absorvem a energia solar deste comprimento de onda e as convertem em calor, fluorescência ou em energia estocada pela fotossíntese (GATES et al., 1965; PONZONI, 2001). Numa curva de reflectância de uma folha verde sadia são bem marcantes duas bandas de absorção centradas em 0,45 μ m (região do azul) e 0,65 μ m (região do vermelho) (GUYOT et al., 1989), permitindo um pico de reflectância em 0,54 μ m na região do verde (SWAIN e DAVIS, 1978). A região do infravermelho próximo é caracterizada pela alta reflectância e pela baixa absorção, causadas pela ausência de substâncias que absorvem a radiação nestes comprimentos de onda e também decorrentes do espalhamento interno causado pelo arranjo do mesófilo (GATES et al., 1965; MOREIRA, 2003).

Na região do infravermelho médio a reflectância da vegetação sofre um decréscimo dos valores da energia refletida devido, principalmente, ao conteúdo de água presente na folha (GUYOT, 1990), estando a reflectância inversamente relacionada com a quantidade total de água (BAUER et al., 1980). O comportamento espectral característico de uma folha sadia varia conforme o comprimento de onda proveniente dos raios solares que incidem sobre a mesma, como se pode observar na figura 1.

comprimentos de onda, como por exemplo no satélite IKONOS II, onde as bandas MS-1, MS-2 e MS-3 estão relacionadas aos comprimentos de onda do visível (0,3 a 0,7 μm) e a banda MS-4 absorve o comprimento de onda do infravermelho próximo (0,7 a 1,3 μm). O tamanho, largura espectral e diferentes resoluções espaciais de alguns destes satélites são apresentados na tabela 1.

Segundo Moreira (2003), existem três categorias de sensores: a) baixa resolução; b) alta resolução e c) os de

Figura 1. Comportamento espectral da vegetação, em diferentes estágios sucessionais



Fonte: Shimabukuro et al. (2003)

Sensores Utilizados para Coleta De Dados

Moreira (2003) comenta que as cenas coletadas pelos sensores podem ser imageadas pelas diferentes categorias de satélite, como os militares, científicos e meteorológicos. Os sensores utilizados para dados em nível orbital estão geralmente voltados para os estudos dos recursos naturais e operam em diferentes números de bandas que estão associadas aos

altíssima resolução, onde estão incluídos os satélites IKONOS e QuickBird. A literatura científica, no entanto, freqüentemente se reporta a esses satélites como sendo de alta resolução.

Processamento de imagens

Segundo Centeno (2004), uma imagem digital é uma representação bidimensional da superfície da terra, sem qualquer preocupação com sua geometria

Tabela 1. Dados de satélites em atividade

Satélite / Sensor	Bandas dos Sensores	Resolução Espacial
Landsat TM	1	30 m
	2	
	3	
	4	
	5	120 m
	6	
	7	
SPOT - HRV (CCD)	XS1	20 m
	XS2	
	XS3	
	PAN	10 m
IKONOS II	MS1	4 m
	MS2	
	MS3	
	MS4	
	PAN	1 m
QuickBird	GSD1	2,44 m
	GSD2	
	GSD3	
	GSD4	
	PAN	0,61 m

Fonte: Adaptado de Moreira (2003)

no mundo real. Portanto a utilização dessas imagens para fins ilustrativos requer que as mesmas sejam corrigidas geometricamente. Todavia, se o desejo for o de se obter informações no âmbito cartográfico, necessário se faz a realização da correção geométrica. Essa correção consiste em obter novas posições para os *pixels* da imagem, de maneira que se introduza a precisão cartográfica do sistema de referência escolhido, além de identificar no terreno a posição de determinado *pixel*. O geo-referenciamento pode ser realizado após a classificação da imagem, porém ter o posicionamento geográfico antes de realizá-la pode agregar informações,

principalmente pelo relacionamento dos *pixels* das imagens com os dados de campo.

Classificar imagens multiespectrais significa atribuir cada *pixel* da imagem a uma determinada classe em função de suas características espectrais. Entendem-se como características espectrais os valores que um determinado *pixel* recebe em cada uma das bandas do satélite. Esses valores variam de 0 a 255 para imagens de 8 *bits* e são definidos em função do tipo de armazenamento de dados na época do advento dos satélites (TODT, 1998).

Existem dois tipos de classificação: a não supervisionada e a supervisionada. Essas podem ser utilizadas como abordagens

alternativas ou, mais freqüentemente, combinadas em metodologias híbridas (CROSTA, 1993). A classificação não supervisionada é indicada quando não se tem conhecimento das possíveis classes existentes na imagem, pois, neste caso, o próprio algoritmo de classificação define as classes e atribui cada um dos *pixels* a uma delas. Assim, de forma automatizada, grupos de *pixels* espectralmente homogêneos correspondem a classes de interesse (MOREIRA, 2003). Esses tipos de classificações sofrem influências topográficas e da umidade ou das características físico-químicas do alvo em questão. No caso da vegetação, as subclasses podem surgir em função da diferença de umidade ou de biomassa, que varia conforme a idade das espécies vegetais (TODT, 1998).

Na classificação supervisionada o usuário define as classes e define amostras no sistema computacional senso utilizado, a partir das quais são estimados parâmetros estatísticos para descrever cada classe. Uma vez definidas as classes e calculados seus descritores, todos os *pixels* da imagem são classificados, aplicando uma regra de decisão com conceitos estatísticos (CENTENO, 2004). As estatísticas que descrevem esta função são a média aritmética e a matriz de covariância extraída de um conjunto de amostras de treinamento.

Como a classificação depende de variáveis estimadas da própria imagem, o conjunto de amostras torna-se um fator decisivo para a obtenção de resultados satisfatórios. Dessa forma, deve-se ter um cuidado especial durante a etapa de coleta de amostras. O conjunto de treinamento deve ser formado por uma quantidade

suficiente de *pixels* representativos e homogêneos de cada uma das classes espectrais consideradas (TODT, 1998). Dentre os métodos de classificação supervisionados existentes destacam-se o método do Paralelepípedo, da Distância Mínima e de Máxima Verossimilhança Gaussiana (CROSTA, 1993).

A maioria dos algoritmos para a classificação digital de imagens, contudo, baseiam-se somente no uso da informação espectral ou tonalidade dos alvos (JENSEN, 1996). Como para mapeamento da biomassa e do carbono orgânico arbóreo é necessário mais do que agrupar em classes e valores espectrais homogêneos, tornam-se necessários levantamentos em campo (inventários florestais), que caracterizem a floresta por meio de suas variáveis biométricas e que devem estar relacionados ao espaço físico (geo-referenciados), para estabelecer uma relação entre os valores extraídos das imagens e os valores de biomassa e carbono orgânico arbóreo oriundos das parcelas do inventário florestal.

Mapeamento de biomassa e carbono orgânico arbóreo

Maciel (2002) procedeu a uma análise de regressão entre as variáveis biométricas e digitais a fim de determinar o grau de dependência entre elas, empregando-se funções lineares e exponenciais, definidas por:

$$Y_i = \alpha + \beta X_i + \varepsilon_i \dots\dots\dots \text{linear}$$

$$Y_i = \alpha + e^{\beta X_i} \cdot \varepsilon_i \dots\dots\dots \text{exponencial, que linearizando, torna-se:}$$

$$\ln Y_i = \ln \alpha + \beta X_i + \ln \varepsilon_i$$

onde:

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

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

α, β = coeficientes de regressão;

ε_i = erro aleatório com média zero e variância constante.

Os dados de campo foram relacionados às imagens por meio de modelos de regressão, procedimento estatístico que utiliza as relações entre duas ou mais variáveis quantitativas para fazer a previsão de uma variável com base em outra ou outras (MACIEL, 2002).

Na análise de regressão, uma variável aleatória y , denominada dependente, é relacionada à outra variável x , independente. No caso a variável biomassa foi considerada como variável dependente e os valores digitais extraídos das imagens, as reflectâncias e os índices de vegetação correspondentes às unidades amostrais considerados como variáveis independentes. Essa metodologia para mapeamento de biomassa e carbono orgânico arbóreo foi utilizada por vários autores, dentre os quais destacam-se Maciel, (2002); Watzlawick, (2003) e Barbosa, (2006).

Usando a metodologia de regressão para correlacionar dados oriundos de imagens de dados de campo para mapear

macro e micronutrientes, Canavesi (2004) e Acco (2004) consideraram como variáveis dependentes os macros e micronutrientes e como variáveis independentes os valores digitais de reflectância, do índice de vegetação (NDVI) e do índice de vegetação ajustado para influência do solo (SAVI). Em todas as análises de regressão realizadas os autores citados, visando julgar qual a melhor equação que estima adequadamente as variáveis dependentes, utilizaram os valores dos coeficientes de determinação ajustados (R^2), o erro padrão da estimativa em porcentagem ($S_{xy}\%$) e a distribuição de resíduos.

Canavesi (2004), trabalhando com macronutrientes como variável independente, obteve um coeficiente de determinação que explica 52% da variação total das amostras por meio das equações ajustadas. Os erros apresentados por Acco (2004), Barbosa (2006) e Watzlawick (2003), foram de 30%, 28%, 23%, respectivamente. O melhor coeficiente de determinação para esses tipos de trabalhos foi o gerado por Maciel (2002), em trabalho realizado em uma floresta primária em Moju, Pará, no qual conseguiu explicar 78% da variação da biomassa, com um erro padrão da estimativa de 10.78%, resultados que, segundo o autor, podem ser considerados ótimos. Cabe salientar que todos os autores citados não separaram amostras para a validação dos modelos, utilizando todas as amostras coletadas para o ajuste dos modelos.

Diante das técnicas normalmente utilizadas, torna-se clara a necessidade do desenvolvimento de uma metodologia que permita o mapeamento da biomassa e do carbono orgânico arbóreo de forma mais eficiente. Para tanto, um modelo que permita integrar diferentes fontes

de entradas de dados, para uma mesma saída e que faça o ajuste de forma mais automatizada, seria o mais adequado e, nesse contexto, as RNA apresentam-se como uma proposta válida.

Bittencourt (1998) descreve que os métodos de RNA têm a capacidade de generalização do aprendizado, de maneira a reconhecer instâncias similares que nunca haviam sido treinadas e que apresentam bom desempenho em tarefas pouco definidas, onde falta o conhecimento explícito sobre como encontrar uma solução. Baseado nisso, um dos ramos da IA, as RNA, podem apresentar bom desempenho para mapeamento do ambiente florestal, onde as coletas de dados de campo são onerosas e trabalhosas.

Para tornar mais eficiente a identificação dos valores de brilho das imagens referentes aos valores médios de biomassa e carbono das parcelas de um inventário florestal, uma simplificação dos dados da imagem torna mais simples essa tarefa. A simplificação, conhecida como segmentação da imagem, consiste em dividir em objetos as regiões espectralmente homogêneas da imagem (MOREIRA, 2001). Os dados biofísicos médios das parcelas e os valores médios de brilho dos segmentos constituem-se nas entradas das RNA, utilizadas para treinar as amostras e, posteriormente, generalizá-las.

Segmentação de imagens

Gonzales e Woods (2000) ressaltam que, para ser eficiente, a segmentação deve isolar os objetos de interesse na imagem. Os algoritmos de segmentação de imagens são muitos específicos e desenvolvidos para cada aplicação. O algoritmo que detecta com grande precisão

um tumor não obteria o mesmo resultado ao tentar detectar um defeito de uma peça numa linha de montagem, não existindo dessa forma, um modelo formal genérico para segmentação. A segmentação é um processo essencialmente empírico e deverá se ajustar a diferentes tipos de imagens (BAATZ e SCHÄPE, 2000) e Rolim (2003).

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

O procedimento de segmentação elaborado pelo programa *e-Cognition* é conhecido como *Multiresolution Segmentation*. A técnica básica utilizada é a de crescimento de regiões por agregação de *pixels* (BAATZ e SCHÄPE, 2000), e Rolim (2003).

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

No crescimento de regiões por agregação de *pixels* ou sub regiões, as mesmas são agrupadas em regiões maiores. As agregações mais simples iniciam-se com um conjunto de pontos “semente” e, a partir destes, as regiões crescem, anexando a cada ponto semente os *pixels* que possuam propriedades similares, como nível de cinza, textura ou cor (GONZALES e WOODS, 2000).

Para os algoritmos de crescimento de regiões segundo a varredura, a imagem é percorrida de cima pra baixo e da esquerda pra direita. Cada ponto (x,y) é comparado com seus vizinhos anteriores já rotulados e adicionado ou não à classe da região de um dos vizinhos. Se um ponto não for adicionado à região de um vizinho, ele deverá iniciar uma nova região (GONZALES e WOODS, 2000). O autor comenta que a principal vantagem de se trabalhar com a classificação por regiões é que essa técnica fornece informações de natureza espacial, que não podem ser extraídas individualmente de *pixels* e que são normalmente consideradas durante o processo de análise visual de imagens.

Redes neurais artificiais (RNA)

Segundo Haykin (1999), a Inteligência Artificial pode ser definida como um conjunto de técnicas de programação que procura resolver problemas em informática pelo uso de programas e algoritmos que procuram imitar o comportamento humano. Dentre as técnicas da Inteligência Artificial destacam-se os Algoritmos Genéticos, a Lógica Fuzzy, os Sistemas Especialistas e as RNA.

A RNA é utilizada basicamente como reconhecedor de padrões, com

a capacidade de reconhecer dados que até então não lhe foram apresentados ou reconhecer dados que não constituíram o conjunto de treinamento. Considerando essas características, o forte das RNA é, sem dúvida, o processamento de sinais. Entende-se por sinais tudo que possibilita conhecer, reconhecer ou prever alguma coisa (TAFNER et al., 1995).

Com o objetivo de representar um evento do sistema nervoso, as RNA foram desenvolvidas a partir do modelo de um neurônio proposto em 1943, por McCulloch e Pitts. Os neurônios do cérebro humano processam informações e se comunicam com milhares de outros neurônios, continuamente e em paralelo.

Uma RNA é um conjunto de elementos processadores individuais (neurônios) com várias entradas e saídas, interconectadas por meio de pesos sinápticos e agrupados sob as mais diversas topologias. Cada neurônio recebe, nas suas entradas, valores das saídas dos neurônios a ele conectados. Esses sinais de entrada (X) são multiplicados pelos respectivos pesos sinápticos das conexões (W) e somados, gerando o valor de ativação do neurônio. O valor de saída do neurônio é aproximadamente binário, resultado da comparação entre o seu valor de ativação e um determinado valor de limiar ou *threshold* (TODT, 1998).

Tafner et al., (1995) descrevem que as entradas de um neurônio artificial podem ser comparadas exatamente com estímulos do neurônio biológico e podem ser modeladas como sendo um circuito binário. Esse circuito binário possui entradas com valores 0 ou 1, que são combinadas pela soma ponderada (corpo celular), gerando a entrada efetiva do neurônio, que determina a continuação desse estímulo. Se o estímulo

for excitatório, ou seja, ultrapassar um limiar, este é enviado a outro neurônio. Os autores comentam que esses estímulos são trazidos até o neurônio simultaneamente, ou seja, um neurônio deve possuir o mesmo número de entradas e de sinais que chegam até o núcleo. Portanto, tanto o neurônio biológico como os artificiais possuem muitas entradas e disparos de saída.

O cérebro humano é responsável pelo que se chama de emoção, pensamento, percepção e cognição, bem como pela execução de funções sensoriomotoras e autônomas. Além disso, sua rede de neurônios tem a capacidade de reconhecer padrões e relacioná-los, usar e armazenar conhecimento por experiência, além de interpretar observações. Não se sabe ao certo a forma como as funções cerebrais são realizadas, mas é nessa estrutura fisiológica que se baseiam as RNA (BRAGA et al., 2000).

Uma RNA é composta por vários neurônios distribuídos em camadas. A primeira camada é chamada entrada e tem a função de armazenar os dados que chegam à rede. As camadas intermediárias, denominadas camadas escondidas, são os “pensamentos” onde ocorrem os processamentos da rede. A última camada, definida como de saída, recebe os valores já processados pela rede. A quantidade de neurônios por camadas, o número de camadas por rede e os pesos ajustados após o aprendizado é chamado de arquitetura da rede neural (ITO et al., 2000).

Os algoritmos utilizados pelas RNA têm a capacidade de reagir a dados de entrada (treinamento) de maneira que alteram seu estado inicial. Pela repetição sucessiva do treinamento, os coeficientes da função de decisão são ajustados e utilizados para a

classificação da imagem (GONZALEZ e WOODS, 1998). Segundo Braga et al. (2000), para incitar o comportamento dos sinais de saída (sinapses), os terminais de entrada do neurônio artificial têm pesos cujos valores podem ser maiores ou menores que zero, dependendo de as sinapses serem inibitórias ou excitatórias. O neurônio dispara quando a soma dos impulsos que ele recebe ultrapassa um limiar de excitação. A ativação do neurônio é feita pela função de ativação que aciona ou não a saída, em função do valor da soma ponderada das entradas.

Algoritmo de redes neurais artificiais

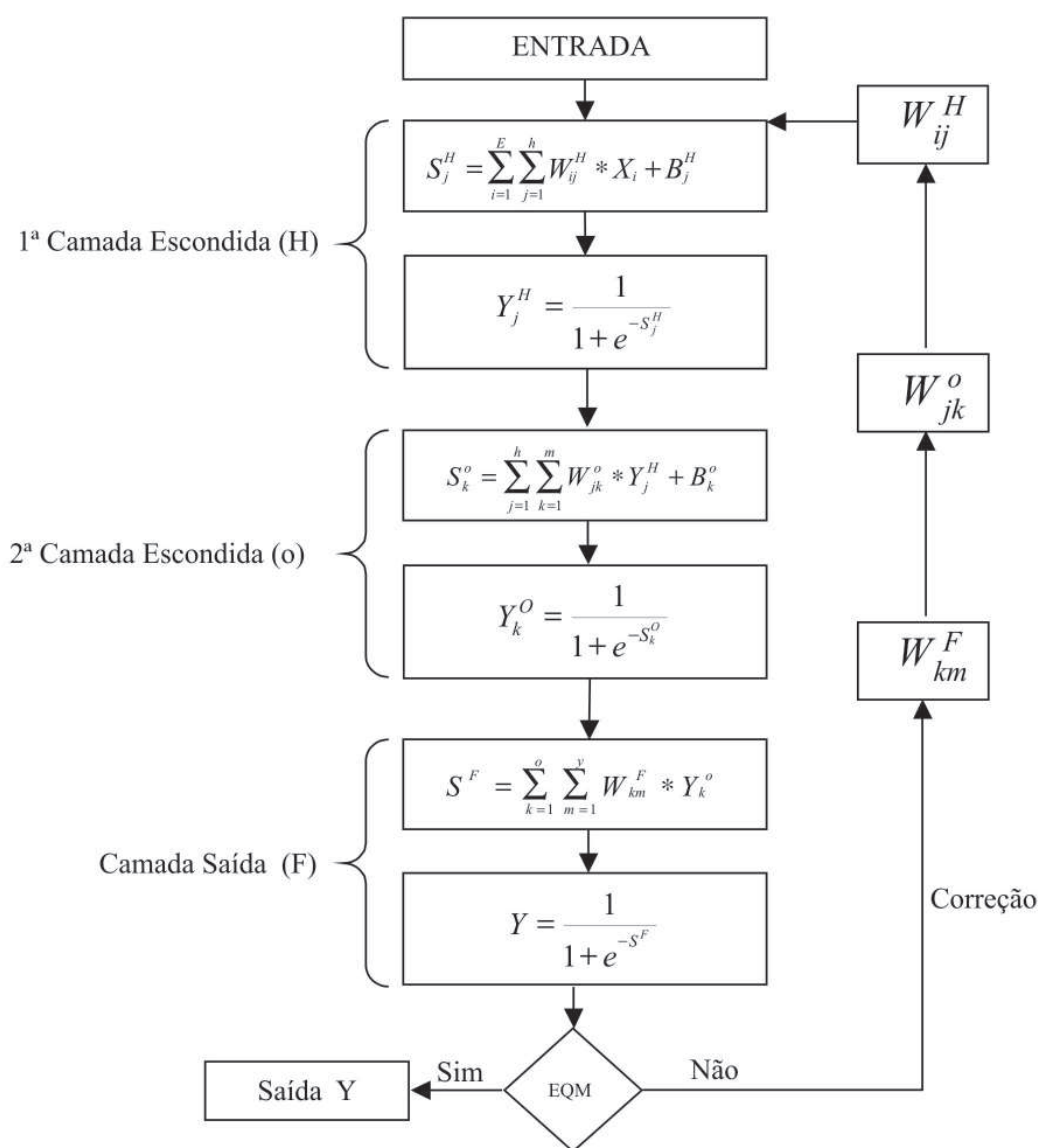
Para o início do processo de aprendizado da RNA é necessário selecionar amostras que possam “treinar” o algoritmo (conjunto de treinamento) e as saídas desejadas correspondentes. As amostras deverão contemplar as variações da área de estudo em número suficiente, devendo serem selecionadas para cada padrão.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

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

Em função de a maioria dos trabalhos práticos aplicados a mapeamento serem não linearmente separáveis, a rede *perceptron* multicamada alimentada adiante (*feedforward*), que utiliza o algoritmo de aprendizagem de retropropagação (*BackPropagation*), gerou

muito interesse pela habilidade em aprender padrões não linearmente separáveis, tendo assim, uso generalizado (BOTELHO, 2004). Para entender melhor a aplicação do algoritmo de RNA, é apresentado o fluxograma mostrado na figura 2, que descreve o fluxo de cálculos

Figura 2. Fluxograma dos procedimentos de cálculos



Fonte: Schoeninger (2006)

dos pesos e dos resultados parciais e finais para a variável desejada.

Segundo Ribeiro (2003), o algoritmo *BackPropagation* baseia-se no Gradiente Descendente do erro, ou seja, na minimização do erro médio quadrado (EQM). Dependendo dos pesos iniciais, do número de neurônios intermediários e do coeficiente de aprendizado, pode acontecer de a RNA atingir um erro mínimo. Se esse mínimo local significar um erro médio quadrado (EQM) aceitável, o aprendizado está realizado, caso contrário é necessário continuar o treinamento.

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

Os procedimentos que envolvem o método *BackPropagation* consideram X como um vetor de entrada que representa um padrão, W como o peso de conexão entre os neurônios da camada escondida e o neurônio de camada de entrada e EQM (Erro Médio Quadrático) como sendo a comparação entre a saída desejada O e Y, a saída obtida pela rede. Para facilitar o entendimento dos procedimentos necessários, a figura 2 apresenta um fluxograma que sintetiza o processo dos

cálculos dos pesos e dos resultados parciais e finais para a variável desejada.

O procedimento de cálculo *Back-Propagation* inicia-se na primeira camada escondida, pela atribuição de pesos aleatórios W e pela especificação do coeficiente de aprendizado e do parâmetro de momento, que serão aplicados ao vetor de variáveis de entrada X e no cálculo dos valores internos de transferência dos neurônios, que são obtidos pela fórmula:

$$S_j^H = \sum_{i=1}^E \sum_{j=1}^h W_j^H * X_i + B_j^H$$

onde:

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

E - número de entradas da arquitetura da rede;

h - número de neurônio da primeira camada oculta;

H - primeira camada oculta;

W_j^H - peso da conexão entre a entrada E e a camada escondida H;

X_i - vetor com as variáveis de entrada;

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

Bias é um neurônio com entrada constante em “1”, sendo que cada

neurônio da camada intermediária e da camada de saída possui o seu próprio *bias*.

A etapa seguinte consiste em ativar os neurônios da primeira camada escondida (H) pelo cálculo de:

$$Y_j^H = \frac{1}{1 + e^{-S_j^H}}$$

onde:

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

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

Para essa ativação, em geral, utiliza-se a função sigmoideal ou a função tangente hiperbólica. Utilizando a função sigmoideal, os neurônios geram valores de ativação dentro do intervalo de -1 a 1, e calculam-se os valores internos (S_k^o) para os m neurônios da Segunda Camada Escondida O pela fórmula:

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

onde:

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

h - número entradas da arquitetura da rede;

m - número de neurônios na segunda camada escondida O;

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

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

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

No passo seguinte a ativação dos neurônios da Segunda Camada Escondida O é obtida pelo cálculo de:

$$Y_k^O = \frac{1}{1 + e^{-S_k^O}}$$

onde:

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

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

Dado que o exemplo demonstrado possui apenas duas camadas, a próxima etapa é o cálculo dos valores estimados, que quando comparados às saídas desejadas, levam à última fase da propagação, pelo cálculo de:

$$S^F = \sum_{k=1}^o \sum_{m=1}^y W_{km}^F * Y_k^O$$

onde:

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

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

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

A seguir é feita a ativação dos neurônios da Camada Saída F pelo cálculo de:

$$Y = \frac{1}{1 + e^{-S^F}}$$

onde:

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

Y - valores estimados;

O processo é encerrado quando o Erro Médio Quadrado (EMQ) do padrão Y for menor ou igual a um erro mínimo previamente estipulado ou ao atingir-se um número determinado de iterações (TODT, 1998) de forma que:

$$EQM = \frac{1}{Y} \sum_{m=1}^Y Ep$$

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

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

onde:

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

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

Taxa de aprendizado variável

Como no gradiente descendente padrão a taxa de aprendizado é constante durante o treinamento pode ocorrer um processamento muito lento se a taxa de aprendizado é pequena ou o algoritmo pode se tornar instável se a taxa fixada é muito alta. Com base nisso, uma solução para se evitar as duas situações é permitir que a taxa de aprendizado seja modificada durante o processo de treinamento (RIBEIRO, 2003). Primeiro fixa-se uma taxa de aprendizado e a saída inicial da rede. Os erros são calculados e, a cada iteração, novos pesos e limiares são encontrados e, utilizando-se a taxa de aprendizado corrente e as novas saídas, os pesos são novamente atualizados. Se o novo erro (calculado) exceder o valor do erro “antigo”, esses pesos e limiares são descartados, caso contrário os pesos e limiares são conservados. Se o novo erro é menor que o antigo, a taxa de aprendizado é aumentada (TODT, 1998).

Variação do treinamento “Backpropagation”: “Momentum”

Pode-se utilizar no processamento do algoritmo *Backpropagation* outra variação chamada de “Momentum”. O “Momentum” é uma taxa que prevê os efeitos das mudanças dos pesos no ajustamento em questão, estabelecendo a

direção para a minimização mais rápida do erro (JARVIS e STUART, 1996).

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

Variação do treinamento “Backpropagation - Resilient”

Ainda devido ao fato de a instabilidade da rede e também do processamento da mesma poder ocorrer de forma lenta, outra variação do treinamento *Backpropagation* foi desenvolvida por ReidMiller e Braun (1993). Neste caso, a atualização feita pela taxa de aprendizado gera um ponto de mínimo local e os pesos podem não ser ajustados a um valor ótimo para o problema. Pode-se então utilizar uma variação do algoritmo “*Backpropagation*” que minimiza esse problema acelerando a convergência esperada da rede. Essa variação chama-se “*Backpropagation Resilient*”, metodologia utilizada por Ribeiro (2003).

Wandresen (2004) cita que o intuito do treinamento “*Resilient*” (elástico) é eliminar os efeitos de perda de magnitude das derivadas parciais. Somente o sinal da derivada é usado para determinar a direção do ajustamento dos pesos. A magnitude das derivadas não tem efeito sobre o ajustamento dos pesos, isto é, a mudança dos pesos é determinada por ajustamento de valores separados. O ajustamento de cada peso é aumentado por um fator todas

as vezes que o desempenho da derivada da função, com respeito aos pesos, tem o mesmo sinal para duas iterações sucessivas. O valor do ajustamento do peso é diminuído por um fator, todas as vezes que a derivada, com respeito aos pesos, muda de sinal na iteração seguinte. Se a derivada é zero, então o valor do gradiente permanece o mesmo. Toda as vezes que os pesos estão oscilando, a mudança dos mesmos será reduzida. Se os pesos continuam a mudar na mesma direção por várias iterações, então sua magnitude do ajuste deles será aumentada (REIDMILLER e BRAUN, 1993).

Aplicação de redes neurais artificiais na área florestal

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

Os valores de biomassa e carbono devem ser extraídos das amostras do inventário florestal, da mesma forma que os valores digitais da imagem (RGB e NIR) referentes a estas amostras. Uma vez pareados, os valores digitais das imagens serão o vetor de entrada (X) e os valores médios de biomassa e carbono para as amostras serão o vetor de resultado desejado (O). O vetor desejado (O) é comparado ao vetor estimado (Y), e nesta fase é calculado o erro médio quadrático (EQM). Se o

erro calculado estiver abaixo do valor aceitável, finaliza-se o algoritmo e é obtido o resultado e, em caso contrário, atualizam-se os pesos e todo o algoritmo é refeito.

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

O treinamento de uma RNA tem como objetivo reconstruir um vetor original e criar padrão (BRAGA et al., 2000 e RIBEIRO 2003). Esses objetivos dependem do tamanho e eficiência do conjunto de treinamento, da arquitetura da rede e da complexidade do problema.

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

Durante a etapa de reconhecimento, cada segmento das áreas amostrais é

fornecido à rede e aquele neurônio de saída cujo valor for maior ou igual a zero é o indicador da classe à qual o segmento pertence. Durante a fase de reconhecimento, a rede gera um arquivo com o valor de biomassa ou carbono de cada valor médio dos níveis de cinza ou valores digital dos segmentos das áreas amostrais. Os resultados finais são gerados pela multiplicação dos pesos, oriundos do treinamento, para toda a imagem segmentada.

Considerações Finais

Os atuais avanços tecnológicos no que se refere ao tratamento digital de imagens de satélite, apoiados em inventários florestais, permitem a caracterização das diferentes estruturas florestais, associando o conteúdo de biomassa e carbono a essas imagens.

No caso de modelos de regressão, esses avanços apoiam a geração de mapas que refletem a distribuição do estoque de biomassa e carbono na floresta, devendo, porém serem considerados os resultados alcançados pelos autores citados no presente.

A integração de dados de campo com a imagem do satélite IKONOS II, baseada em IA e RNA para estimar o estoque de biomassa e carbono orgânico arbóreo, apresenta-se como uma metodologia promissora para o desenvolvimento de mapas temáticos dessa natureza, agilizando e melhorando a exatidão das estimativas.

A automatização e a integração de dados para a quantificação de dados de biomassa e carbono, utilizando como metodologia de apoio imagens de satélite e RNA, podem minimizar os custos e melhorar a precisão e exatidão dos mesmos.

Referências

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

AFFONSO, A.G. *Caracterização de fisionomias vegetais na Amazônia Oriental através de vidiografia aerotransportada e imagens Landsat 7 ETM+*. 2004. 120f. São José dos Campos. Dissertação (Mestrado em Sensoriamento Remoto) - Instituto Nacional de Pesquisas Especiais. São Paulo.

AVERY, T.E.; BERLIN, G.L. *Fundamentals of remote sensing and airphoto interpretation*. New Jersey: Prentice Hall. 1992. 472 p.

APPENZELLER, T. O caso da fuga do carbono. *National geographic Magazine Portugal*. 2004. Disponível em <<http://www.nationalgeographic.pt/revista/0204/feature5/default.asp>> Acesso em: 10 jan. 2006.

BAATZ, M.; SCHÄPE, A. Multiresolution segmentation: an optimization approach for high quality multi-scale image segmentation. 2000. Disponível em <www.definiens.com> Acesso em: 12 mar. 2006.

BARBOSA, K.M. Monitoramento espacial de biomassa e carbono orgânico da vegetação herbácea de várzea na Amazônia Central. Curitiba: 2006, 155f. Tese (Doutorado em Ciências Florestais – Manejo Florestal) - Universidade Federal do Paraná.

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

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

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

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

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

CARBONOBRAZIL. Mercado de carbono. Mudanças climáticas. Disponível em: <<http://www.carbonobrasil.com/textos.asp?tId=60&idioma=1>> Acesso em: 10 jan. 2006.

CENTENO, J. A. S. Sensoriamento remoto e processamento de imagens digitais. Curitiba: Curso de Pós Graduação em Ciências Geodésicas, Universidade Federal do Paraná. 2004. 209p.

- CREPANI, E. *Princípios básicos de sensoriamento remoto*. São José dos Campos: CNPQ/INPE, 1993. 45p.
- CROSTA, A. P. *Processamento digital de imagens de sensoriamento remoto*. Campinas: Revista Campinas. IG/UNICAMP. 1993. 170p.
- GATES, D. M. *Biophysical ecology*. New York: Springer-Verlag. 1980. 611p.
- GATES, D.M.; KEEGAN, H. J.; SCHLETER, J. C.; WEIDER, V. R. Spectral properties of plants. *Applied Optics*, v.4, n.1, p.1-20, 1965.
- GONZALEZ, R. C.; WOODS, R. E. *Digital image processing*. New Jersey, Addison-Wesley Publishing Company. 1998. 630p.
- GONZALEZ, R. C.; WOODS, R. E. *Processamento de imagens digitais*. São Paulo: Ed. Edgard Blücher. 2000. 509p.
- GOSE E.; JOHNSONBAUGH, R.; JOST, S. *Pattern RNA recognition and image analysis*. New Jersey: Prentice Hall, Inc. 1996. 484p.
- GUYOT, L.A.; GUYON, D.; RIOM, J. Factors affecting the spectral response of forest canopies: a review. *Geocarto International*, v. 4, n.3, p. 3-18, 1989.
- GUYOT, G. Optical properties of vegetation canopies. In: STEVEN, M. D.; CLARK, J. A. *Applications of remote sensing in agriculture*. London: Butterworths. 19-43p. 1990.
- HAYKIN, S. *Neural networks. A comprehensive foundation*. 2 Ed. New Jersey: Prentice Hall. 1999. 842p.
- ITO, Y.; HOSOKAMA, M.; LEE, H.; LIU, J. G. Extraction of damaged regions using SAR data and neural networks. *International Archives of Photogrammetric Engineering and Remote Sensing*. v.33, part B1, p. 156-163. 2000.
- JACKSON, R. D.; HUETE, A. R. Interpreting vegetation indices. *Preventive Veterinary Medicine*. v.11, n.4, p. 185-200, 1991.
- JARVIS, H. C.; STUART, N. The sensitivity of neural network for classifying remotely sensed imagery. *Computers Geosciences*. v.22, n.9, p. 959 – 967, 1996.
- JENSEN, J. R. *Introductory digital image processing*. Ed.2. New Jersey: Prentice-Hall. 1996.
- KOFFER, N. F. Técnicas de sensoriamento remoto orbital aplicadas ao mapeamento da vegetação e uso da terra. *Geografia*. v.17, n.2, 14-17p, 1992.
- MACIEL, M. N. M. Estimativa de parâmetros estruturais de uma floresta primária na Amazônia oriental através de dados orbitais. 2002, 124f. Tese (Doutorado em Ciências Florestais-Manejo Florestal) - Universidade Federal do Paraná. Curitiba.
- MASCARENHAS, N.; VELASCO, F. *Processamento digital de imagens*. São Paulo: Instituto de Matemática e Estatística, 1989.

- MATLAB. User's Guide – Neural Network Toolbox. Version 6.5. Math Works. 2001.
- MOREIRA, M. A. *Fundamentos do sensoriamento remoto e metodologias de aplicação*. São José dos Campos: INPE. 2001. 249p.
- MOREIRA, M. A. *Fundamentos do sensoriamento remoto e metodologias de aplicação*. 2. ed. Viçosa: UFV. 2003. 307p.
- PONZONI, F. J. Comportamento Espectral da vegetação. In: MENESES, P.R.; MADEIRA NETTO, J. S. *Sensoriamento Remoto: Reflectancia dos alvos naturais*. Brasília: Planaltina EMBRAPA Cerrados. 2001. 262p.
- RENNER, R. *Seqüestro de carbono e a viabilização de novos reflorestamentos no Brasil*. 2004, 116f. Dissertação (Mestrado em Ciências Florestais – Manejo Florestal) - Universidade Federal do Paraná. Curitiba.
- REIDMILLER, M.; BRAUN, H. A direct adaptive method for faster backpropagation learning: the RPROP algorithm. In: International Conference on Neural Network (ICNN), 1993. San Francisco: Proceedings. San Francisco, p.586 – 591, 1993.
- RIBEIRO, S. R. A.. *Integração de Imagens Landsat TM e dados auxiliares para a delimitação automática de unidades fisionômicas usando Redes Neurais Artificiais*. 2003, 160f. Tese (Doutorado em Ciências Geodésicas) - Setor de tecnologia - Universidade Federal do Paraná. Curitiba.
- ROLIM, F. A. *Classificação orientada a objeto em imagens de alta resolução para auxílio ao monitoramento ambiental em uma microbacia hidrográfica*. Curitiba: 2003, 120f. Dissertação (Mestrado em Ciências Florestais-Manejo Florestal) - Universidade Federal do Paraná.
- SHIMABUKURO, Y. E.; MIURA, T.; HUETE, A. R.; ARAI, E.; ESPIRITO-SANTO, F.; LATORRE, M. L. Análise dos Dados Hyperespectrais do EO-1 Obtidos sobre a Floresta Nacional de Tapajós no Estado do Pará. Belo Horizonte: XI Simpósio Brasileiro de Sensoriamento Remoto. 2003.
- SWAIN, P. H.; DAVIS, S. M. *Remote Sensing: The quantitative approach*. New York: McGraw-Hill, 1978. 396p.
- TAIZ, L.; ZEIGER, E. *Fisiologia Vegetal*. Trad. SANTARÉM, E.R. et al. 3 ed. Porto Alegre: Artmed. 184-188p. 2004.
- TAFNER, M. A.; XEREZ, M.; RODRIGUES I. W. F. *Redes neurais artificiais: introdução e princípios de neurocomputação*. Blumenau: FURB. 1995. 190p.
- TODT, V. *Avaliação do desempenho de classificadores neurais para aplicações em sensoriamento remoto*. Porto Alegre: 1998, 232f. Dissertação (Mestrado em Engenharia Florestal) - Universidade Federal do Rio Grande do Sul.
- WANDRESEN R. *Integração entre redes neurais e correlação para identificar pontos de apoio pré-sinalizados*. 2004, 158f. Tese (Doutorado em Ciências Geodésicas) - Universidade Federal do Paraná. Curitiba.

SCHOENINGER, E.R. et al.

WATZLAWICK, L. F. *Estimativa de Biomassa e Carbono em Floresta Ombrófila Mista Montana, utilizando dados de campo e dados obtidos a partir de imagens do satélite IKONOS II*. Curitiba: 2003, 129f. Tese (Doutorado em Ciências Florestais - Manejo Florestal) - Universidade Federal do Paraná.