

Um Novo Método para a Predição do Sequestro de Carbono em Áreas de Reflorestamento usando Rede Neural

Clodoaldo Nunes, Valquíria R. C. Martinho, Carlos R. Minussi

Laboratório de Sistemas Inteligentes - SINTEL, Departamento de Engenharia Elétrica

Faculdade de Engenharia de Ilha Solteira, Universidade Estadual Paulista-UNESP

Ilha Solteira - SP, Brasil.

cncfet@gmail.com , vrbreiro@terra.com.br , minussi@dee.feis.unesp.br

Abstract— Economic and industrial activities have increased the rate of emission of greenhouse gases (GHG) on the planet. In recent decades, there has been a process that's going to increase the temperature of the globe, depending on the rate of increase of emissions of these greenhouse gases, mainly from emissions of carbon dioxide (CO₂). Thus, it becomes essential to adopt measures to reduce carbon emissions, and also, the development of efficient methods for quantifying the flow of carbon into the atmosphere. This research investigates an intelligent system to quantify emissions and carbon sequestration in deforested areas, in the short, medium and long term. The proposed system consists of a combination ART neural network-fuzzy architecture and a multilayer feedforward neural network with training performed through the use of the retropropagation algorithm, making the quantifying and predicting of the carbon absorption more accurate and precise than the original methods. Aiming to test the proposed system, we present an application in an area located in a reforested area in the Amazon region of Mato Grosso-Brazil, on a farm with land area of approximately 10.000 hectares.

Keywords—*Estimation of Carbon; Neural Networks; Reforestation Area.*

I. INTRODUÇÃO

Nos últimos anos, o aumento das emissões e concentrações de gás carbônico (CO₂) na atmosfera, por causa do desmatamento desenfreado, às mudanças no uso da terra e à queima de combustíveis fósseis, tem contribuído para o aumento do efeito estufa e, conseqüentemente, do aquecimento global, promovendo alterações climáticas que ameaçam a vida no planeta [1].

Dentre as medidas para redução da emissão de gases poluentes ou Gases de Efeito Estufa (GEE) está a manutenção da floresta nativa, o reflorestamento de áreas desmatadas ou plantio de árvores em outras áreas. Para obter resultados satisfatórios e obter benefícios econômicos e ambientais, associados à mitigação desses gases e, com isso, amenizando o fenômeno do aquecimento global, é necessário utilizar eficazmente o potencial das florestas tropicais, enquanto sumidouro de carbono, para diminuição dos GEE [2] [3].

Nesse contexto, é de grande relevância, para a continuidade dos ecossistemas e para sustentabilidade do planeta e de suas espécies, que o fluxo resultante da emissão e captação de gás carbônico da atmosfera, em áreas de florestas in natura ou reflorestamentos, seja metodologicamente aferido e com significativo grau de confiabilidade. Isto possibilita, inclusive,

predizer o comportamento futuro, inferindo sobre a quantidade de carbono absorvido pela área analisada.

Tendo em vista que os dados ecológicos e as variáveis envolvidas nos processos de emissão e sequestro de gás carbônico (as trocas de gases) são complexas e não-lineares e, também, a variabilidade de seus parâmetros mais relevantes, como, por exemplo árvores de espécies e idades diferentes, com índices de crescimento distintos, tipo de solo, temperatura ambiente, luminosidade e tantas outras características e informações que interferem na variação dos níveis de troca de CO₂, usar técnicas da inteligência artificial [4], como as Redes Neurais Artificiais (RNAs) [5], é uma alternativa viável para lidar com essas situações de não-linearidade, complexidade e variabilidade. Sendo as RNAs ferramentas computacionais inspiradas no comportamento do modelo biológico do cérebro humano, elas processam a informação e aprendem por meio de experiências e, com isso, possuem considerável capacidade de generalização. Essa característica permite o desenvolvimento de sistemas capazes de lidar com dados imperfeitos, ausentes ou ruidosos e, ainda, manter o resultado esperado.

Dentre as publicações científicas pertinentes a tecnologias e métodos para a análise e quantificação do fluxo de carbono e relevantes para o propósito deste trabalho, encontra-se o método de modelagem de fotossíntese no nível da folha do jatobá [6], utilizando uma rede neural feedforward com a técnica de treinamento retropropagação, ou simplesmente, rede neural backpropagation (BP) [7], considerado o trabalho precursor nesta área de estudo. Recentemente, a relação do Fluxo de Carbono (FC) e fatores ambientais foi analisada [8], utilizando um modelo de predição com base na rede Wavelet [9] e, posteriormente, o modelo foi comparado com a rede neural BP e a máquina de vetor de suporte (SVM) [5], levando em consideração a estrutura de rede, a precisão e a taxa de convergência.

Neste artigo, apresenta-se um sistema inteligente capaz de realizar a predição do fluxo de carbono, a médio e longo prazo, em áreas de reflorestamento, inferindo de maneira fidedigna qual a real situação que se apresentará determinada área analisada [1]. Este sistema, de predição e quantificação de carbono foi desenvolvido utilizando uma das técnicas da inteligência artificial, as RNAs e, mais especificamente, uma composição formada por uma rede neural da família ART (*Adaptive Resonance Theory*) [10] [11], a ART-Fuzzy [12] e uma rede neural feedforward multicamadas com treinamento executado via uso do algoritmo retropropagação [7] [13] (que, neste artigo, por conveniência, é

designada Rede Neural BP). O sistema inteligente final é designado “Rede Neural ART-*Fuzzy*-BP”. Este sistema, considerando-se o experimento proposto, evidencia um desempenho satisfatório (precisão e baixo custo computacional) conferindo-o como um método alternativo interessante de predição do fluxo de carbono em áreas reflorestadas.

Este artigo está estruturado da seguinte maneira: na Seção 2 são descritas a definição da área de estudo e a construção da base de dados. O desenvolvimento do sistema é apresentado na Seção 3. Nas Seções 4 e 5 são abordados, sucintamente e respectivamente, os conceitos do algoritmo de treinamento BP e da rede neural ART-*Fuzzy*. Na Seção 6 descreve-se a implementação do sistema, apresentam-se os resultados e as análises dos testes. Finalizando este trabalho, as conclusões mais relevantes são apresentadas na Seção 7.

II. DEFINIÇÃO DO PROBLEMA E A SOLUÇÃO PROPOSTA PARA A PREDIÇÃO DO FLUXO DE CARBONO

A. Definição da Área de Estudo

A região estudada localiza-se na fazenda São Nicolau situada ao norte do Estado de Mato Grosso, na região sul da Amazônia, aproximadamente a 950 km da cidade de Cuiabá-MT e a 45 km do município de Cotiguaçu-MT, definida pelas coordenadas geográficas de longitude 58° 15' 31.1 W” e latitude 09° 49' 09.0” S, localizada hidrograficamente a margem esquerda do rio Juruena e, com temperaturas variando entre 23° a 25°C, com uma extensão territorial de aproximadamente 10.000 hectares [1].

O interesse para esta aplicação são os dados coletados na área de reflorestamento, através do inventário florestal de campo. Para o replantio da área desmatada foram utilizadas 2 milhões de árvores, sendo 49 espécies nativas e 2 consideradas exóticas, a Teca e o Jamelão. A área reflorestada foi dividida em pequenos sítios de plantios, denominados talhões (Fig. 2). Estes talhões são numerados, para facilitar sua identificação, localização e controle do desenvolvimento das plantações



Fig. 1. Localização da área de pesquisa.

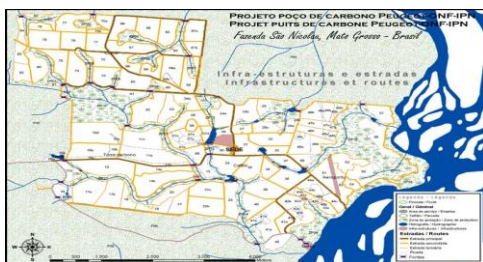


Fig. 2. Localização e numeração dos talhões na área reflorestada.

B. Construção da Base de Dados

Para a predição da quantidade de carbono arbórea na área de reflorestamento, anteriormente descrita, será considerada dados invariantes no tempo (parâmetros de identificação do problema: espécie de árvore, número do talhão, etc.) e dados cujos valores irão variando à medida que as árvores crescem no reflorestamento.

O banco de dados é composto de informações retiradas do inventário de campo de cada talhão, no período de 2003 a 2010. Os dados invariantes no tempo, que compõem a base de dados são: número do talhão, identificação da árvore, espécie ou nome comum, características do solo (fósforo, pH, textura, quantidade de alumínio), distância entre o talhão e a mata ciliar, espaçamento entre as árvores e quantidade de espécies por talhão. As características variantes no tempo, conforme o crescimento da espécie arbórea, são as medidas de altura da árvore (H) e a Circunferência à Altura do Peito (CAP) [14], ou seja, a circunferência do tronco medida a altura a 1,3 m do solo. Estas medidas foram realizadas anualmente.

Neste trabalho será avaliado apenas dois talhões com base em informações retiradas do banco de dados do inventário florestal, para isso, adotar-se-á um procedimento considerando-se somente uma árvore representativa do conjunto de árvores que, para fins de identificação neste artigo, será designada “Árvore Padrão (AP)”. O parâmetro DAP_m da AP é definido da seguinte forma:

$$DAP_m = \sum_{k=1}^N m_k DAP_k \quad (1)$$

sendo:

DAP : Diâmetro à altura do peito

DAP_m : DAP da árvore padrão

DAP_k : DAP da k -ésima espécie

$$DAP_k = \frac{\sum CAP_k}{\pi n_k} \quad (2)$$

$$m_k = \frac{n_k}{\sum_{j=1}^N n_j} \quad (3)$$

Esta estratégia, baseada na média ponderada do DAP , tem produzido bons resultados. Contudo, outras formas de definição da AP podem ser empregadas visando melhorar ainda mais os resultados auferidos. Por exemplo, o uso da lógica *Fuzzy* [15], teoria de evidência de Dempster-Shafer [16], entre outras.

III. REDE NEURAL ART-FUZZY-BP

A rede neural a ser usada (Fig. 3) é composta por 2 módulos: (1) ART-*Fuzzy*; (2) Rede neural feedforward multicamadas com treinamento realizado usando-se o algoritmo BP (Rede Neural BP). Esta estrutura é adotada, tendo em vista que o problema a ser resolvido (estimativa da absorção de carbono em áreas reflorestadas) é idealizado a partir de dois grupos de dados, ou seja, dados binários (maior quantidade de informações) e dados pertencentes ao corpo dos números reais. Estes dois grupos são definidos da seguinte forma:

$$a = [nt \ ia \ nc \ cs \ dt \ ea \ qe] \quad (4)$$

$$\mathbf{b} = [d \text{ DAPm}(t)] \quad (5)$$

sendo: t : tempo discreto;

Na Tabela I, estão especificadas as grandezas invariantes no tempo.

Os subvetores nt , ia , \dots , e qe do vetor \mathbf{a} são vetores linhas que contêm a representação binária das grandezas invariantes temporais. Cada bit corresponde a um componente do vetor associado.

O vetor \mathbf{d} contém informações sobre a evolução do crescimento da árvore-padrão, ou seja, são os valores de $DAPm$ medidos em 3 tempos distintos: $(t-3)$, $(t-2)$ e $(t-1)$. O vetor \mathbf{b} é constituído pelo vetor \mathbf{d} acrescido do valor $DAPm(t)$ que corresponde à realimentação da saída y , considerando-se um atraso igual a t (unidade de tempo). A saída corresponde à previsão em um intervalo de tempo à frente. Esta proposta consiste no deslocamento de uma janela temporal abrigoando, por exemplo, quatro instantes sequenciais (dados passados e o tempo corrente). Outras estratégias, que visem melhorar o desempenho do sistema predictor, podem ser perfeitamente implementadas.

O vetor \mathbf{a} representa a entrada do módulo ART-Fuzzy (rede neural não-supervisionada). A saída deste módulo são as classes auto-organizadas pelo módulo ART-Fuzzy. A classe escolhida (Ω) (saída deste módulo) é convertida em um vetor binário (Ψ) via processamento do módulo "código-ativo". O vetor binário Ψ , juntamente com a entrada \mathbf{b} (5), formam o vetor \mathbf{x} de entrada da rede neural BP. Deste modo, o modelo de entrada-saída da rede neural BP é descrito por:

$$\mathbf{x} = [\mathbf{b} \ \Psi] \quad (\text{entrada da rede neural BP}) \quad (6)$$

$$\mathbf{y} = [DAPm(t+1)] \quad (\text{saída da BP}) \quad (7)$$

Observa-se que nesta proposta, a saída da rede neural ART-Fuzzy-BP possui somente 1 componente que é a $DAPm(t+1)$. Porém, há possibilidade de usar diferentes informações visando atender outras necessidades, se houver interesse.

IV. REDE NEURAL BP

O treinamento via uso do algoritmo retropropagação, é iniciado pela apresentação de um padrão \mathbf{x} à rede neural, o qual produzirá uma saída \mathbf{y} . Em seguida, calcula-se o erro de cada saída (diferença entre o valor desejado e a saída). O próximo passo consiste na determinação do erro propagado no sentido inverso, através da rede associada à derivada parcial do erro quadrático de cada elemento com relação aos pesos e, finalmente, ajustando os pesos de cada elemento. Um novo padrão é apresentado. Assim, o processo é repetido, para todos os padrões, até que ocorra a total convergência ($|\text{erro}| \leq \text{tolerância}$ preestabelecida).

Os pesos iniciais são normalmente adotados como números aleatórios. O algoritmo BP consiste na adaptação de pesos com o propósito de minimizar o erro quadrático da rede neural. A soma do erro quadrático instantâneo de cada neurônio alocado na última camada (saída da rede neural) é dada por [17]:

TABELA I. GRANDEZAS INVARIANTES NO TEMPO.

nt	ia	nc	cs	dt	ea	qe
Nº do talhão	Identificação da árvore	Especies	Características do Solo	Distância entre árvores	Espaçamento entre árvores	Quantidade Especies
8 bits	5 bits	5 bits	6 bits	2 bits	5 bits	4 bits




Fig. 3. Sistema neural ART-Fuzzy-BP.

$$\varepsilon^2 = \sum_{i=1}^{ns} \varepsilon_i^2 \quad (8)$$

sendo:

$$\varepsilon_i = d_i - y_i ;$$

d_i : saída desejada do i -ésimo elemento da última camada da rede;

y_i : saída do i -ésimo elemento da última camada da rede;

ns : número de neurônios da última camada da rede.

Considerando-se o neurônio de índice i da rede neural, e utilizando-se o método do gradiente descendente [13], o ajuste de pesos pode ser formulado como [5], [13]:

$$\mathbf{V}_i(h+1) = \mathbf{V}_i(h) + \theta_i(h) \quad (9)$$

sendo:

$$\theta_i(h) = -\gamma [\nabla_i(h)] \quad (10)$$

γ : parâmetro de controle da estabilidade ou taxa de treinamento;

h : representa o índice de iteração;

$\nabla_i(h)$: gradiente do erro quadrático com relação aos pesos do neurônio i avaliado em h ;

\mathbf{V}_i : vetor contendo os pesos do neurônio i

onde:

$$\mathbf{V}_i = [w_{0i} \ w_{1i} \ w_{2i} \ \dots \ w_{ni}] .$$

Em (9), a direção adotada, para minimizar a função objetivo do erro quadrático corresponde à direção contrária ao vetor-gradiente. O parâmetro γ determina o comprimento do vetor $[\theta_i(h)]$.

A função sigmoide é definida por [5], [13]:

$$y_i = \frac{1 - \exp(-\lambda s_i)}{1 + \exp(-\lambda s_i)} \quad (11)$$

ou

$$y_i = \frac{1}{1 + \exp(-\lambda s_i)} \quad (12)$$

sendo:

λ : constante que determina a inclinação da curva y_i .

Ressalta-se que o espectro de variação da função sigmoide y_i dada por (11) ou (12) é $[-1, +1]$ ou $[0, +1]$, respectivamente.

O algoritmo BP é abordado na literatura sob várias formas com o propósito de torná-lo mais rápido computacionalmente. Uma formulação bastante interessante é o algoritmo retropropagação com momento [13], o qual possui um efeito estabilizador:

$$\mathbf{V}_{ij}(h+1) = \mathbf{V}_{ij}(h) + \Delta \mathbf{V}_{ij}(h) \quad (13)$$

sendo:

$$\Delta V_{ij}(h) = 2\gamma(1-\eta)\delta_j(h)X_j + \eta\Delta V_{ij}(h-1) \quad (14)$$

V_{ij} : peso sináptico de interligação entre os neurônios i e j ;
 η : constante de momento, $0 \leq \eta \leq 1$;
 δ_j : derivada do erro quadrático (gradiente);
 \mathbf{x} : vetor de entrada.

Os modos de treinamento podem ser de dois tipos, o chamado sequencial e por lote. O sequencial é aquele em que o ajuste dos pesos é efetuado após a apresentação de cada padrão e o lote com todos os padrões ao mesmo tempo [13].

Então, efetuando-se o cálculo do gradiente como indicado em (10), considerando-se a função sigmoide definida por (11) ou (12) e o termo momento, obtém-se o seguinte esquema de adaptação de pesos [13]:

$$V_{ij}(h+1) = V_{ij}(h) + \Delta V_{ij}(h) \quad (15)$$

sendo:

$$\Delta V_{ij}(h) = 2\gamma(1-\eta)\beta_j x_i + \eta\Delta V_{ij}(h-1) \quad (16)$$

V_{ij} : peso correspondente à interligação entre o i -ésimo e j -ésimo neurônio.

Se o elemento j encontrar-se na última camada, então:

$$\beta_j = \sigma_j \varepsilon_j \quad (17)$$

sendo:

σ_j : derivada da função sigmoide dada por (11) ou (12), respectivamente, com relação a s_j :

$$\sigma_j = 0,5\lambda(1-y_j^2) \quad (18)$$

$$\sigma_j = \lambda y_j(1-y_j) \quad (19)$$

Se o elemento j encontrar-se nas demais camadas, tem-se:

$$\beta_j = \sigma_j \sum_{k \in R(j)} w_{jk} \beta_k \quad (20)$$

sendo:

$R(j)$: conjunto dos índices dos elementos que se encontram na fileira seguinte à fileira do elemento j e que estão interligados ao elemento j .

O parâmetro γ serve como um agente de controle da estabilidade do processo iterativo.

Os pesos da rede são inicializados aleatoriamente considerando-se o intervalo $[0,1]$ [13].

V. REDE NEURAL ART-FUZZY

A rede neural ART é composta por três camadas: F_0 (camada de entrada); F_1 (camada de comparação); F_2 (camada de reconhecimento) que armazena as categorias (clusters). O algoritmo desta rede neural consiste, basicamente, nos seguintes passos [12]:

Passo 1: Dados de entrada

Os dados de entrada são denotados pelo vetor $\mathbf{a} = [a_1 \ a_2 \ a_3 \ \dots \ a_M]$. Este vetor deve ser da seguinte forma:

$$\bar{\mathbf{a}} = \frac{\mathbf{a}}{|\mathbf{a}|}, \text{ sendo: } |\mathbf{a}| = \sum_{i=1}^M a_i \quad (21)$$

sendo:

$\bar{\mathbf{a}}$: vetor de entrada normalizado;

$|\mathbf{a}|$: norma do vetor de entrada \mathbf{a} ;

a_i : elemento do vetor de entrada \mathbf{a} com índice i .

Passo 2: Codificação do vetor de entrada

A codificação de complemento é realizada para preservar a amplitude da informação, ou seja:

$$\bar{a}_i^c = 1 - \bar{a}_i \quad (22)$$

sendo:

$\bar{\mathbf{a}}^c$: vetor complementar de entrada normalizado.

Deste modo, o vetor de entrada pode ser escrito por:

$$\mathbf{I} = \begin{bmatrix} \bar{\mathbf{a}} & \bar{\mathbf{a}}^c \end{bmatrix} \quad (23)$$

$$\mathbf{I} = \begin{bmatrix} \bar{a}_1 & \bar{a}_2 & \dots & \bar{a}_M & \bar{a}_1^c & \bar{a}_2^c & \dots & \bar{a}_M^c \end{bmatrix}$$

sendo:

$$|\mathbf{I}| = \sum_{i=1}^M \bar{a}_i + \sum_{i=1}^M \bar{a}_i^c \quad (24)$$

= M (todos os vetores com normalização e codificação complementada terão mesmo comprimento M).

Passo 3: Vetor de atividade

O vetor de atividade de F_2 é simbolizado por $\boldsymbol{\Omega} = [\Omega_1 \ \Omega_2 \ \dots \ \Omega_N]$, sendo N o número de categorias criadas em F_2 . Deste modo, tem-se:

$$\Omega_j = \begin{cases} 1, & \text{se o nó } j \text{ de } F_2 \text{ é ativo} \\ 0, & \text{caso contrário} \end{cases}$$

Passo 4: Parâmetros da rede neural

Os parâmetros usados no processamento da rede ART-Fuzzy são:

- Parâmetro de escolha : $\alpha > 0$;
- Parâmetro de treinamento : $\beta \in [0, 1]$;
- Parâmetro de vigilância : $\rho \in [0, 1]$.

Passo 5: Inicialização dos pesos

Inicialmente todos os pesos possuem valores iguais a 1, ou seja:

$$w_{j1}(0) = w_{j2M}(0) = \dots = w_{NM}(0) = 1 \quad (25)$$

indicando que não existe nenhuma categoria ativa.

Passo 6: Escolha da categoria

Dado o vetor de entrada \mathbf{I} em F_1 , para cada nó j em F_2 , a função de escolha T_j é determinada por:

$$T_j(\mathbf{I}) = \frac{|\mathbf{I} \wedge \mathbf{w}_j|}{\alpha + |\mathbf{w}_j|} \quad (26)$$

sendo:

\wedge : operador AND Fuzzy, definido por:

$$(\mathbf{I} \wedge \mathbf{w})_i = \min(I_i, w_i)$$

A categoria escolhida associada ao nó J ativo, ou seja:

$$J = \arg \max_{j=1, \dots, N} T_j \quad (27)$$

Usando-se (27), se existir mais de uma categoria ativa, a categoria escolhida será aquela que possuir menor índice.

Passo 7: Ressonância ou Reset

A ressonância ocorre se o critério de vigilância (28) for satisfeito:

$$\frac{|I \wedge w_j|}{|I|} \geq \rho \quad (28)$$

Caso o critério definido em (28) não seja satisfeito, ocorre o dispositivo chamado reset. No reset, o nó J de F_2 é excluído do processo de busca, ou seja, adotando-se $T_j = 0$. Então, é escolhida uma nova categoria através de (27) para o processo de ressonância. Este procedimento será realizado até que a rede encontre uma categoria que satisfaça (28).

Passo 8: Atualização dos pesos (Treinamento)

Após o vetor de entrada I ter completado o estado de ressonância, segue o processo de treinamento, no qual ocorre a modificação do vetor peso dada por:

$$w_j^{\text{novo}} = \beta (I \wedge w_j^{\text{velho}}) + (1 - \beta) w_j^{\text{velho}} \quad (29)$$

sendo:

J : categoria ativa;

w_j^{novo} : vetor peso atualizado,

w_j^{velho} : vetor peso referente à atualização anterior.

Se $\beta = 1$, tem-se o treinamento rápido.

VI. APLICAÇÃO E ANÁLISE DE RESULTADOS

Na aplicação do sistema inteligente, “Rede Neural ART-Fuzzy - BP”, proposto para realizar a predição do fluxo de carbono, foi utilizado uma base de dados composta por 4433 linhas e 38 colunas do talhão 1 e 1885 linhas e 38 colunas do talhão 2. Cada linha corresponde a uma árvore analisada e representa os vetores padrão de entrada e sua correspondente saída desejada. Os dados das colunas de 1 a 35 representam os atributos correspondentes ao vetor a (entrada da rede neural ART-Fuzzy), representação binária das grandezas invariantes temporais. Nas colunas 36, 37 e 38 estão os atributos variantes no tempo que compõem os pares de vetores padrão de entrada d (e, conseqüentemente, a constituição do vetor b) e a da saída y , conforme indicados na Fig. 3. As linhas da base de dados foram subdivididas para a análise específica de cada talhão por elas representado.

Após a subdivisão da base de dados, utilizando-se a Rede Neural ART-Fuzzy, módulo 1 do sistema, e considerando as grandezas invariantes temporais de cada árvore do talhão, encontrou-se, na saída deste módulo, a classe representativa de cada talhão (Ω). As classes são auto-organizadas pelo módulo ART-Fuzzy, tendo em vista que se trata de uma rede neural não-supervisionada. Em seguida, através do processamento do módulo “código-ativo”, a classe (Ω) que representa o talhão foi convertida em um vetor binário (ψ). Uma demonstração desta etapa do processo pode ser visualizada na Fig. 4. Na Tabela II, estão

especificados os parâmetros usados na fase de treinamento da rede ART-Fuzzy.

Utilizando-se o módulo 2 do sistema - Rede Neural BP, foi implementada a técnica de janelamento para encontrar o DAP_m da árvore-padrão dos talhões em análise. Neste experimento, para a implementação do janelamento, adotou-se um período de tempo anual, de janeiro a dezembro, de 2003 a 2014, sendo que de 2003 a 2010 o valor do DAP_m era conhecido.

Nesta técnica, foram consideradas as grandezas variantes no tempo que representavam o crescimento da árvore padrão do talhão em análise, de dois anos sucessivos e anteriores ao ano que se desejava a previsão.

O resultado do processo de janelamento juntamente com o vetor binário (ψ) classe representativa do talhão, constituíram o vetor de entrada da rede BP. Na saída deste módulo obteve-se, sob a forma do DAP_m , uma previsão da absorção de carbono dos talhões analisados para um intervalo de tempo à frente. Esta fase do processo está demonstrada na Fig. 5.




Fig. 4. Processamento da rede neural ART-Fuzzy.

TABELA II. PARÂMETROS DA REDE ART-FUZZY.

Parâmetros	Valores
Parâmetro de Vigilância (ρ)	0,99
Taxa de treinamento (β)	1,0
Parâmetro de escolha (α)	0,1




Fig. 5. Processamento da rede neural BP.

Após o processo de janelamento e treinamento da rede neural BP, a previsão do DAP_m foi realizada e os resultados da Rede Neural ART-Fuzzy-BP, sistema proposto neste experimento para previsão da absorção de carbono, estão demonstrados no gráfico da Fig. 6 e Fig. 7.

Considerando o experimento realizado e analisando os resultados obtidos, verificou-se que a absorção de carbono encontrada com as simulações foi aferida com aquelas já conhecidas e com significativo grau de confiabilidade, permitindo o conhecimento de maneira fidedigna da real situação que se apresentava a área analisada.

Na Fig. 6 e 7 observa-se, com clareza, as aproximações dos resultados entre os valores do DAPm, ou seja, os valores alvo e os valores do DAPm da saída da rede proposta, tendo um erro médio entre elas em torno de 0,02, podendo provar que a absorção do carbono foi metodologicamente aferida e com significativo grau de confiabilidade.

VII. CONCLUSÕES

O presente estudo propôs uma nova metodologia, através de técnicas de redes neurais, objetivando prever o sequestro de carbono, a curto, médio e longo prazo. Este método usa uma Rede Neural ART-Fuzzy-BP composto por dois módulos: (1) ART-Fuzzy; (2) Rede neural feedforward multicamadas com treinamento realizado usando-se o algoritmo BP (Rede Neural BP).

Os resultados evidenciam que a contribuição através da Rede Neural ART-Fuzzy-BP foi alcançada no sentido de se fazer, a previsão a curto, médio e longo prazo da absorção do gás carbônico em áreas de reflorestamento, colaborando de certa forma, através desta pesquisa, para que se adotem medidas que possam minimizar os impactos no meio ambiente e amenizar o agravamento do aquecimento global, garantindo também a sustentabilidade do planeta.

AGRADECIMENTOS

Os autores agradecem a indústria automobilística Peugeot, em parceria com a estatal francesa Office National des Forêts (ONF), pelo apoio e disponibilização da base de dados do inventário florestal.




Fig. 6. Previsão do carbono do Talhão 1.




Fig. 7. Previsão do carbono do Talhão 2.

REFERÊNCIAS

- [1] C. Nunes, "Predição do Sequestro do Carbono em Áreas Reflorestadas utilizando Redes Neurais Artificiais," Exame Geral de Qualificação (Doutorado em Engenharia Elétrica), Programa de Pós-Graduação em Engenharia Elétrica (PPGEE), Departamento de Engenharia Elétrica, Faculdade de Engenharia de Ilha Solteira, Universidade Estadual Paulista - UNESP, Ilha solteira - SP, 2012.
- [2] A. LeBlanc, "Issues related to including forestry-based offsets in a GHG emissions trading system," *Environmental Science & Policy*, vol. 2, pp. 199-206, 1999.
- [3] C. H. R. T. Silva, "COP16 - Metas Voluntárias e Reforma do Código Florestal : o desmatamento no Brasil e a mitigação da mudança global do clima," Centro de Estudos da Consultoria do Senado Federal," ed, 2010.
- [4] E. A. Bender, *Mathematical methods in artificial intelligence*. Los Alamitos, Calif. : IEEE Computer Society Press, 1996.
- [5] S. S. Haykin, *Neural Networks and Learning Machines*: Prentice Hall, 2009.
- [6] M. L. B. Barriga Puente de La Vega, "Fitomonitoração e modelagem de fotossíntese em jatobá (*Hymenaea courbaril* L.) com redes neurais artificiais.," (Tese de Doutorado), Programa de Pós-Graduação em Engenharia elétrica, Escola Politécnica da Universidade de São Paulo, São Paulo, 2003.
- [7] P. Werbos, "Beyond Regression: New Tools for Prediction and Analysis in the Behavioral Sciences," Harvard University, 1974.
- [8] K. Wang, X. Yue-ju, J. King, H.-m. Chen, and C. Qiang, "Prediction of carbon flux based on wavelet networks," pp. 1553-1556, 2011.
- [9] I. Daubechies, *Ten Lectures on Wavelets*: Society for Industrial and Applied Mathematics, 1992.
- [10] G. A. Carpenter and S. Grossberg, "A self-organizing neural network for supervised learning, recognition, and prediction," *Comm. Mag.*, vol. 30, pp. 38-49, 1992.
- [11] S. C. Marchiori, M. d. C. G. Silveira, A. D. P. Lotufo, C. R. Minussi, and M. L. M. Lopes, "Neural network based on adaptive resonance theory with continuous training for multi-configuration transient stability analysis of electric power systems," *Appl. Soft Comput.*, vol. 11, pp. 706-715, 2011.
- [12] G. A. Carpenter, S. Grossberg, and D. B. Rosen, "Fuzzy ART: Fast stable learning and categorization of analog patterns by an adaptive resonance system," *Neural Netw.*, vol. 4, pp. 759-771, 1991.
- [13] B. Widrow and M. A. Lehr, "30 years of adaptive neural networks: Perceptron, Madaline, and backpropagation," *Proceedings of the IEEE*, vol. 78, pp. 1415-1442, 1990.
- [14] C. R. Sanquetta, L. F. Watzlawick, R. Balbinot, M. A. B. Ziliotto, and F. S. Gomes, *As florestas e o carbono*. Curitiba, 2002.
- [15] L. A. Zadeh, "Fuzzy sets," *Information and Control*, vol. 8, pp. 338-353, 1965.
- [16] L. A. Klein, *Sensor and Data Fusion: A Tool for Information Assessment and Decision Making*: SPIE Press, 2004.
- [17] M. L. M. Lopes, C. R. Minussi, and A. D. P. Lotufo, "Electric load forecasting using a Fuzzy ART & ARTMAP neural network," *Applied Soft Computing*, vol. 5, pp. 235-244, 2005.