

PREDIÇÃO DO SEQUESTRO DE CARBONO COM ESPÉCIES ARBÓREAS NATIVAS DA AMAZÔNIA POR REDES NEURAIAS ARTIFICIAIS

CLODOALDO NUNES¹, VALQUÍRIA R. C. MARTINHO², CARLOS R. MINUSSI³

1. *Departamento de Informática, Instituto Federal de Mato Grosso – IFMT- Campus Cuiabá
Rua Zulmira Canavarros, 93 - Centro Cuiabá / MT, Brasil - CEP: 78005-200*
2. *Departamento de Eletro Eletrônica, Instituto Federal de Mato Grosso – IFMT- Campus Cuiabá
Rua Zulmira Canavarros, 93 - Centro Cuiabá / MT, Brasil - CEP: 78005-200*
3. *Laboratório de Sistemas Inteligentes, Faculdade de Engenharia Elétrica de Ilha Solteira - UNESP
Av Brasil, 56 – Centro Ilha Solteira / SP, Brasil - PO Box 31, CEP: 15385-000*

*E-mails: cncefet@gmail.com, vribeiro@terra.com.br,
minussi@dee.feis.unesp.br*

Abstract— The increase in emissions and concentrations of carbon dioxides in the atmosphere has brought the intensification of greenhouse effect and, consequently, climatic changes and imbalance on the planet. Therefore, it becomes essential to adopt measures and develop efficient methods for quantifying and evaluating the emission of flow of carbon in the atmosphere by land vegetation. Thus, this research aims to propose the development of an intelligent system, based on the use of neural networks to predict and quantify, whether in the short, medium or long term, the carbon sequestration in reforestation areas, on a 8939 hectares farm located in the Amazon. The proposed system was developed using a composition formed by a neural network of the ART family (Adaptive Resonance Theory), the Fuzzy-ART 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. It is highlighted that this proposal is innovative, because it can approach large areas of plantations, with diversity of trees, among other important factors in this context. That is, it is an intelligent system robust and of great flexibility of application.

Keywords— Estimation of Carbon, Neural Networks, Reforestation Area.

Resumo— O aumento das emissões e concentrações de gás carbônico na atmosfera tem ocasionado à intensificação do efeito estufa e, conseqüentemente, das alterações climáticas e desequilíbrio sobre o planeta. Deste modo, torna-se imprescindível a adoção de medidas e o desenvolvimento de métodos eficientes para quantificar e avaliar a emissão do fluxo de carbono na atmosfera pela vegetação terrestre. Assim sendo, esta pesquisa tem por objetivo propor o desenvolvimento de um sistema inteligente, baseado no emprego de redes neurais para prever e quantificar, seja a curto, médio ou em longo prazo, o sequestro de carbono em áreas de reflorestamento, em uma fazenda situada na Amazônia com 8.939 hectares. O sistema proposto foi desenvolvido utilizando uma composição formada por uma rede neural da família ART (Adaptive Resonance Theory), a ART-Fuzzy e uma rede neural feedforward multicamadas com treinamento realizado via uso do algoritmo retropropagação, quantificando e fazendo a previsão com maior acurácia e precisão da absorção de carbono, do que os métodos originais. Ressalta-se que esta proposta é inovadora, pois pode-se abordar de áreas com diversidade de árvores, de grande extensões plantadas, entre outros fatores importantes neste contexto. Ou seja, trata-se de um sistema inteligente robusto e de grande flexibilidade de aplicação.

Palavras-chave— Estimativa do Carbono, Redes Neurais, Área Reflorestada.

1 Introdução

Nas últimas décadas, as emissões de gases poluentes ou Gases de Efeito Estufa (GEE), têm contribuído significativamente para a intensificação do aquecimento global, responsável pelo aumento das alterações climáticas no planeta. Dentre esses gases, o aumento das emissões e concentração de gás carbônico (CO₂) na atmosfera, advinda do mau uso da terra, da queima dos combustíveis fósseis, da remoção da cobertura vegetal e, principalmente, do desmatamento sem controle das florestas nativas, é considerado o maior responsável por esse aquecimento.

Face a isso, é preciso, pois, tomar providências que garantam a redução da emissão desses gases, refletindo-se em medidas preventivas e necessárias que possam mitigar o aquecimento global, subsidiadas por meios que garantam a captura de sequestro de carbono, revertendo sua contribuição para as mudanças do nosso clima. Como exemplo, tem-se: a rotação de pastagem com lavouras, práticas do manejo do solo, adoção de sistemas florestais e manejo da floresta. Estes últimos garantem o reflorestamento de áreas já derrubadas, contribuindo assim para conter o desmatamento ilegal de grande parte das florestas.

Nesse contexto, para obter resultados satisfatórios e alcançar um desenvolvimento ecologicamente sustentável, capaz de gerar benefícios econômicos, sociais e ambientais segundo LeBlanc (1999), em projetos para sequestro de carbono, em áreas de florestas in natura ou de reflorestamentos, é necessário utilizar o potencial das florestas, para se estimar, com precisão, de forma fidedigna, visando quantificar e conhecer a taxa de fixação de estoque de carbono nos ecossistemas, conforme Silva (2010).

A prática do reflorestamento e florestamento, naturalmente, são as formas mais comuns para a absorção ou sequestro do excesso de carbono na atmosfera, pois, na fase de crescimento das árvores, pelo processo da fotossíntese, elas demandam uma grande quantidade de carbono para se desenvolver e acabam contribuindo para reduzir as consequências dos GEE.

A grande maioria dos dados ecológicos e das variáveis envolvidas no processo de trocas de CO₂ apresenta um certo grau de complexidade e não-linearidade. Além disso, esse processo sofre interferência com a variabilidade de parâmetros relevantes como as espécies e idades das árvores, os ciclos de crescimento, a composição do solo, a temperatura e a luminosidade dos ecossistemas naturais. Uma possibilidade exequível para representar situações de não-linearidade, complexidade e variabilidade é a utilização de Redes Neurais Artificiais (RNAs) segundo Edward (1996), um dos diversos paradigmas da Inteligência Artificial encontrado em Simon (2008). As Redes Neurais são, basicamente, modelos matemáticos computacionais que se inspiram na forma com que o cérebro interpreta as informações e aprendem por meio de experiências. 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.

Ressalta-se que na literatura, encontram-se poucas referências que tratam da análise e quantificação do fluxo de carbono através do emprego de redes neurais artificiais. Considerando os trabalhos percursoros nesta área, relevantes para o estudo desta pesquisa, vale destacar o projeto de Fitomonitoração e modelagem da fotossíntese no nível da folha do Jatobá conforme Madeleine(2003), a investigação da estimativa da biomassa florestal, através de imagens de sensoriamento remoto encontrado em Werbos (1974), ambos baseados em aplicações de redes neurais artificiais, especificamente com a rede neural feedforward multicamadas com treinamento executado via uso do algoritmo de aprendizagem de retropropagação, conhecido como BackPropagation baseado em Kai (2011)(que, neste artigo, por conveniência, é designada Rede Neural BP). E ainda Daubechies (1992), um estudo referente a análise da relação do

Fluxo de Carbono e fatores ambientais, utilizando um método de predição, baseado na rede Wavelet conforme Carpenter (1992), e posteriormente comparado com a rede neural BP e a máquina de vetor de suporte (SVM) em Simon(2008).

Neste presente estudo, propõem-se um sistema inteligente, através de técnicas de inteligência artificial, baseado nas RNAs, capaz de realizar a predição do fluxo de carbono, em áreas de reflorestamento e florestamento, seja a curto, médio ou de longo prazo, inferindo de maneira fidedigna qual a real situação das áreas analisadas. Este sistema trata-se de uma composição formada por uma rede neural da família ART (Adaptive Resonance Theory) em Marchiori (2011); Carpenter (1991), a ART-Fuzzy segundo Carpenter (1992) e uma rede neural feedforward multicamadas com treinamento executado via uso do algoritmo retropropagação Widrow (2002), designado por Rede Neural ART-Fuzzy-BP.

Após esta introdução, a Seção 2 apresenta a definição do problema e a solução proposta para prever o fluxo de carbono da área de estudo e a construção da base de dados. O desenvolvimento do sistema é demonstrado na Seção 3. Na Seção 4, descreve-se a implementação do sistema, apresentam-se os resultados e as análises dos testes. O artigo termina com as considerações finais mais relevantes apresentadas na Seção 5.

2 Definição do Problema e a Solução proposta para a Predição do Carbono

2.1 Definição da área de estudo

A região estudada localiza-se no noroeste do Estado de Mato Grosso, situada a 45 km do município de Cotiguaçu, precisamente na fazenda São Nicolau, definida pelas coordenadas geográficas de longitude 58° 20' 35,6''W e latitude 9° 48' 30,1'' S, com uma altitude de 260 metros.

A fazenda apresenta uma vegetação de floresta Aberta e Densa, uma área de Reserva Particular do Patrimônio Natural – RPPN, e ainda, uma área de reflorestamento com quase 1.418,36 hectares. Para o interesse desta pesquisa, serão analisadas as informações coletadas das unidades amostrais identificando as espécies arbóreas ou arbustivas que foram plantadas para recompor áreas que foram desmatadas.

Para fazer o plantio das espécies florestais, foram feitas pequenas subdivisões, gerando a formalização de grupos de talhões, que foram numerados e identificados para facilitar o controle e a localização e ainda, o comportamento do plantio dos quase dois milhões de árvores, advindas do inventário florestal, sendo este um documento, essencial para fornecer subsídios para essa pesquisa, onde se arquiva a base de dados do desenvolvimento de cada uma das espécies, desde que foram plantadas.

Nesses talhões foram plantadas árvores de 49 espécies nativas e mais duas consideradas exóticas, conhecidas por Teca e Jamelão. Em alguns talhões, foram plantadas árvores da mesma espécie e, em outros, de espécies diferentes. Tais informações são importantes para a predição da quantidade de carbono absorvido por essas árvores.

2.2 Construção da Base de Dados

Neste trabalho são avaliados três talhões com base em informações retiradas do banco de dados do inventário florestal.

O primeiro talhão identificado como talhão 1, encontra-se situado nas coordenadas de longitude 9°50'31.56"S e latitude 58°15'58.27"O. Com uma área de 9,06 hectares e um total de 4.433 espécies de árvores plantadas conforme demonstrado na Figura 1.




Figura 1. Distribuição de espécies do talhão 1.

O talhão 2 de coordenadas geográficas 9°50'46.95"S de longitude e 58°15'49.61"O de latitude. Com uma área de 40,66 hectares e com uma plantação de 18.855 árvores, conforme ilustrado na Figura 2.




Figura 2. Distribuição de espécies do talhão 2.

A Figura 3 é o último talhão a ser analisado, denominado pelo talhão 4, situado à 9° 51'8.02"S de latitude e 58°15'30.89"O de Longitude, abrangendo uma área de 7,11 hectares e 7.139 árvores plantadas.




Figura 3. Distribuição de espécies do talhão 4.

As informações referentes a esses talhões foram retiradas do inventário florestal da fazenda, com dados invariantes no tempo dos seguintes

parâmetros: número do talhão, identificação da árvore, nome comum, características do solo, distância entre o talhão e a mata ciliar, espaçamento entre as árvores e quantidade de espécies.

Os dados de crescimento das mudas de espécies arbóreas, medidos anualmente, através das medidas de altura(H) e da Circunferência à Altura do Peito (CAP) e do Diâmetro à Altura do Peito (DAP) convencionados pela medida da Circunferência e Diâmetro do tronco das árvores a 1,30 m do solo, são considerados dados variantes no tempo.

Adotar-se-á somente uma árvore para representar o conjunto de árvores a fim de tornar mais simples o sistema inteligente que, para fins de identificação, será designada pela "Árvore Padrão", sem comprometer a qualidade das soluções. O parâmetro DAP_m da Árvore Padrão(AP) pode ser obtido através da seguinte forma:

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

sendo:

DAP_m : DAP da árvore padrão

DAP_k : DAP da k-ésima espécie

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

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

3 Rede Neural ART-Fuzzy-BP

A rede neural a ser usada (Figura 4) é composta por 2 módulos: (1) ART-Fuzzy; (2) Rede neural *feedforward* multicamadas com treinamento realizado usando-se o algoritmo BP (Rede Neural BP). O desenvolvimento matemático e os algoritmos para o processamento de uma Rede Neural BP e a Rede Neural ART-Fuzzy, são encontrados, respectivamente, em Carpenter et al.(1991) e em Widrow (1990), e utilizados em Nunes et al.(2013).

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:

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

$$\mathbf{b} = [\mathbf{d} \ \mathbf{DAP}_m(t)] \quad (5)$$

t : tempo discreto;

Na Tabela 1, estão especificadas as grandezas invariantes no tempo.

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

O vetor **d** contém informações sobre a evolução do crescimento da árvore-padrão, ou seja, são os valores de DAP_m medidos em 3 tempos distintos: (t-3), (t-2) e (t-1). O vetor **b** é constituído pelo vetor **d** acrescido do valor $DAP_m(t)$ 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. Por exemplo, o tempo a ser considerado poderá ser mensal, ou outra referência a critério do usuário.

Esta proposta consiste no deslocamento de uma janela temporal abrangendo, 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 sem necessidade de alterações importantes.

O vetor **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 **b** (equação (5)), formam o vetor **x** de entrada da rede neural BP. Deste modo, o modelo de entrada-saída da rede neural BP é descrito por:

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

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

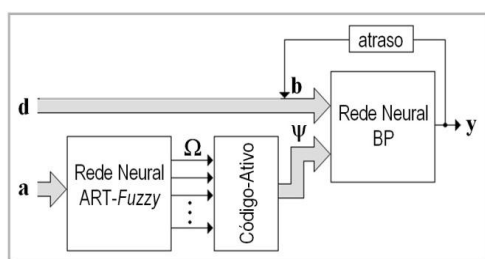


Figura 4. Sistema neural ART-Fuzzy-BP

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

Tabela 1. Grandezas Invariantes no Tempo.

<i>nt</i>	<i>ia</i>	<i>nc</i>	<i>cs</i>	<i>dt</i>	<i>ea</i>	<i>qe</i>
Número do talhão	Identificação da árvore	Espécie ou nome comum	Características do solo	Distância entre o talhão e a mata ciliar	Espaçamento entre as árvores	Quantidade de espécies por talhão
8 Bits	5 bits	5 bits	6 bits	2 bits	5 bits	4 bits

4 Aplicação e Análise de Resultados

Para realizar a aplicação do sistema inteligente, “Rede Neural ART-Fuzzy-BP”, proposto para fazer a previsão do fluxo de carbono, a rede neural foi treinada com dados referentes ao inventário florestal da fazenda, coletados entre os anos 2003 e 2010. Os dados utilizados neste trabalho têm como origem três diferentes talhões, conforme especificados na tabela 2.

As linhas correspondem a cada uma das árvores que foram plantadas, dos talhões já citados, e representam o vetor padrão de entrada e a sua correspondente saída desejada.

Na Figura 5 tem-se o vetor **a** da entrada da rede neural ART-Fuzzy, representado pelos atributos dos dados das colunas de 1 a 35 que representam as grandezas binárias invariantes no tempo. Os atributos variantes do tempo, originários da coluna 36,37 e 38, compõem os pares de vetores padrão de entrada **d** e, consequentemente, a constituição do vetor **b** e da saída **y**.

Para a análise exploratória dos dados foi considerado somente o grupo de espécies das árvores da família do Parica com 1532 árvores e a Teca com 2954 árvores, por serem comuns entre os três talhões.

Após a subdivisão da base de dados para cada talhão, 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 com dados da espécie arbórea da Teca pode ser visualizada na Figura 5. Na Tabela 3, estão especificados os parâmetros usados na fase de treinamento da rede ART-Fuzzy.

Tabela 2. Representação dos Talhões.

Talhões	Espécies	Base de Dados	Plantio
1	Parica, Caja, Cedro Rosa e Teca	38 colunas e 4433 linhas	1999
2	Parica, Mogno, Ipê Amarelo, Caxeta, Caroba, Caju, Caja e Teca	38 colunas e 18855 linhas	1999/2000
4	Mogno, Ipê Roxo, Cerejeira, Caxeta, Caja, Teca, Pinho Cuiabano, Parica	38 colunas e 7139 linhas	1999/2000

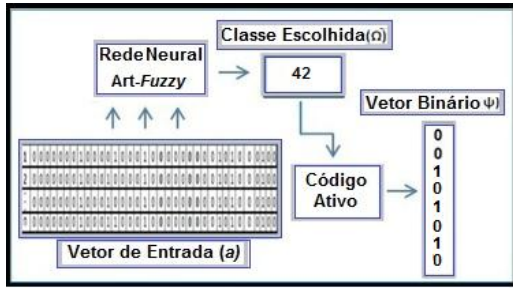


Figura 5. Processamento da rede neural ART-Fuzzy.

Utilizando-se o módulo 2 do sistema - Rede Neural BP, foi implementada a técnica de janelamento para encontrar o DAP_m da árvore-padrão de cada um 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 dos talhões 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 de cada 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 nos talhões analisados para um intervalo de tempo à frente. Esta fase do processo está demonstrada na Figura 6.

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 para a espécie arbórea da Teca, e Parica dos talhões 1,2 e 4, sistema proposto neste experimento para previsão da absorção de carbono, estão demonstrados no Gráfico da Figura 7 e da Figura 8.

TABELA 3. PARÂMETROS DA REDE ART-FUZZY.

Parâmetros	Valores
Parâmetro de Vigilância (ρ)	0,99
Taxa de treinamento (β)	1,00
Parâmetro de escolha (α)	0,10

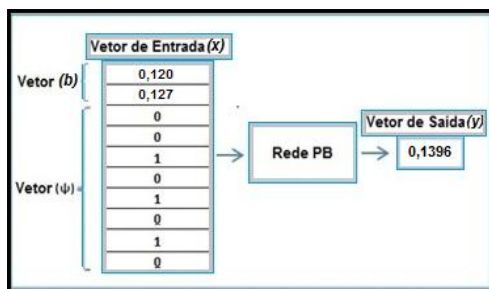


Figura 6. Processamento da rede neural BP.




Figura 7. Previsão do CO₂ - Teca.




Figura 8. Previsão do CO₂ - Parica.

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.

Foi possível constatar e identificar, através da análise dos resultados obtidos, que o sistema mostrou-se adequado (erro inferior a 0,02%), ou seja, com significativo grau de confiabilidade no que diz respeito à metodologia adotada, comparada com outros trabalhos da literatura, citados na introdução deste artigo.

Na Figura 7 e 8 observam-se, com clareza, as aproximações dos resultados entre os valores do DAP_m, ou seja, os valores alvo e os valores do DAP_m da saída da rede proposta, tendo um erro médio entre elas em torno de 0,02.

5 Conclusões

O objetivo do presente estudo é propor um novo método, através das redes neurais artificiais, para a predição do sequestro de carbono, a médio e longo prazo, em áreas reflorestadas e de florestamento das espécies arbóreas Teca e Parica. Neste sentido, foi implementado a Rede Neural ART-Fuzzy-BP composta por dois módulos: (1) ART-Fuzzy; (2) Rede neural *feedforward* multicamadas com treinamento realizado usando-se o algoritmo BP (Rede Neural BP).

Sendo assim, pode-se concluir que a contribuição desse artigo foi alcançada, no sentido de investigar a eficiência do uso da Rede Neural ART-Fuzzy-BP

para a predição da absorção do CO₂ em áreas florestadas e de reflorestamento, seja a curto, médio e longo prazo, colaborando desta forma para que se adotem medidas para minimizar os impactos futuros do aumento da temperatura global e garantir a sustentabilidade do planeta.

Agradecimentos

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 para o interesse dessa pesquisa.

Referências Bibliográficas

- Almeida, A. C; Barros, P. L. C; Monteiro, J. H. A., and Rocha, B. R. P.(2009). "Estimation of aboveground forest biomass in Amazonia with neural networks and remote sensing," IEEE Latin Amer. Trans., vol. 7, no. 1, pp. 27-32, Mar. 2009.
- Bender, E. A. (1996). *Mathematical methods in artificial intelligence*. Los Alamitos, Calif. :: IEEE Computer Society Press.
- Carpenter, G. A. and Grossberg, S.(1992), "A self-organizing neural network for supervised learning, recognition, and prediction," *Comm. Mag.*, vol. 30, pp. 38-49.
- Carpenter, G. A.; Grossberg, S. and Rosen, D. B. (1991), "Fuzzy ART: Fast stable learning and categorization of analog patterns by an adaptive resonance system," *Neural Netw.*, vol. 4, pp. 759-771
- Daubechies, I. (1992). *Ten Lectures on Wavelets*: Society for Industrial and Applied Mathematics.
- Haykin, S. S. (2009), *Neural Networks and Learning Machines*: Prentice Hall.
- Klein, L. A. (2004) *Sensor and Data Fusion: A Tool for Information Assessment and Decision Making*: SPIE Press.
- LeBlanc, A (1999). "Issues related to including forestry-based offsets in a GHG emissions trading system," *Environmental Science & Policy*, vol. 2, pp. 199-206.
- Lopes, M. L. M.; Minussi, C. R., and Lotufo, A. D. P. (2005) "Electric load forecasting using a Fuzzy ART & ARTMAP neural network," *Applied Soft Computing*, vol. 5, pp. 235-244.
- Marchiori, S. C.; Silveira, M. d. C. G.; Lotufo, A. D. P.; Minussi, C. R. i, and Lopes, M. L. M. (2011). "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.
- Nunes, C.; Martinho, V.R.C. and Minussi, C.R. (2013). "A New Method for the Prediction of Carbon Sequestration in Reforested Areas Using a Fuzzy-ART-BP Neural Network ". XV International Conference on Artificial Intelligence - ICAI'2013. Las Vegas, USA: Proceedings of the ICAI'13. (no prelo).
- Puente de La Veja, M. L. B. (2003). "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.
- Sanquetta, C. R.; Watzlawick, L. F.; Balbinot, R; Ziliotto, M. A. B and Gomes, F. S. (2002) *As florestas e o carbono*. Curitiba.
- Silva, C. H. R. T. (2010). "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*".
- Wang, K.; Yue-ju, X.; King, J.; Chen, H.-m., and Qiang, C. (2011). "Prediction of carbon flux based on wavelet networks," pp. 1553-1556.
- Werbos, P. (1974) "Beyond Regression: New Tools for Prediction and Analysis in the Behavioral Sciences," Harvard University.
- Widrow, B. and Lehr, M. A. (1990). "30 years of adaptive neural networks: Perceptron, Madaline, and backpropagation," *Proceedings of the IEEE*, vol. 78, pp. 1415-1442.
- Zadeh, L. A. (1965) "Fuzzy sets," *Information and Control*, vol. 8, pp. 338-353.