



UNIVERSIDADE ESTADUAL PAULISTA
"JÚLIO DE MESQUITA FILHO"
Câmpus de Ilha Solteira

Programa de Pós-Graduação em Engenharia Elétrica

CLODOALDO NUNES

**Predição do Sequestro do Carbono em Área Reflorestada
utilizando Redes Neurais Artificiais**

Ilha Solteira
2013

CLODOALDO NUNES

**Predição do Sequestro do Carbono em Área Reflorestada
utilizando Redes Neurais Artificiais**

Tese apresentada à Faculdade de Engenharia
do Campus de Ilha Solteira – UNESP como
parte dos requisitos para obtenção do título de
Doutor em Engenharia Elétrica.

Especialidade: Automação.

Prof. Dr. Carlos Roberto Minussi
Orientador

Ilha Solteira
2013

FICHA CATALOGRÁFICA

Desenvolvido pelo Serviço Técnico de Biblioteca e Documentação

N972p Nunes, Clodoaldo .
Predição do sequestro do carbono em área reflorestada utilizando redes neurais artificiais / Clodoaldo Nunes. -- Ilha Solteira: [s.n.], 2014
94 f. : il.

Tese (doutorado) - Universidade Estadual Paulista. Faculdade de Engenharia de Ilha Solteira. Área de conhecimento: Automação, 2014

Orientador: Carlos Roberto Minussi

Co-orientador:

Inclui bibliografia

1. Estimativa do carbono. 2. Redes neurais. 3. Área reflorestada. 4. Sustentabilidade do planeta.



UNIVERSIDADE ESTADUAL PAULISTA
CAMPUS DE ILHA SOLTEIRA
FACULDADE DE ENGENHARIA DE ILHA SOLTEIRA


CERTIFICADO DE APROVAÇÃO

TÍTULO: Predição do Sequestro do Carbono em Área Reflorestada Utilizando Redes Neurais Artificiais

AUTOR: CLODOALDO NUNES

ORIENTADOR: Prof. Dr. CARLOS ROBERTO MINUSSI

Aprovado como parte das exigências para obtenção do Título de DOUTOR EM ENGENHARIA ELÉTRICA, Área: AUTOMAÇÃO, pela Comissão Examinadora:




Prof. Dr. CARLOS ROBERTO MINUSSI

Departamento de Engenharia Elétrica / Faculdade de Engenharia de Ilha Solteira




Profa. Dra. MARIA DO CARMO G DA SILVEIRA

Departamento de Engenharia Elétrica / Universidade Estadual Paulista "Júlio de Mesquita Filho"



Profa. Dra. MARA LÚCIA MARTINS LOPES

Departamento de Matemática / Faculdade de Engenharia de Ilha Solteira



Prof. Dr. MARCOS AMORIELLE FURINI

Instituto Federal de São Paulo, Campus Votuporanga



Prof. Dr. ARNULFO BARROSO DE VASCONCELLOS

Departamento de Engenharia Elétrica / Universidade Federal de Mato Grosso

Data da realização: 07 de fevereiro de 2014.

DEDICATÓRIA

Aos meus pais, Damião e Terezinha

Aos meus filhos, Gabriel Henrique e Caio Victor

Ao meu irmão, Paulo César.

AGRADECIMENTOS

Agradeço, primeiramente a Deus, por estar presente em todos os momentos da minha vida, concedendo-me saúde, força, inteligência e disposição, proporcionando-me o equilíbrio necessário para concluir mais essa etapa da minha vida.

Aos meus pais, Damião e Terezinha e aos meus irmãos, por tudo que fizeram e fazem por mim, sempre me orientando, com muito respeito, carisma e afeto, desde muito pequeno, que o melhor caminho seria sempre o estudo e, que nesse etapa, torceram, acreditaram e me apoiaram até o último momento.

Ao meu orientador, Prof. Dr. Carlos Roberto Minussi, pela amizade, conselhos, pelos conhecimentos transmitidos e sábias orientações com muita dedicação e seriedade, cujas contribuições tornaram possível a realização desta tese.

À Universidade Estadual de São Paulo- UNESP de Ilha Solteira, por intermédio do Departamento de Engenharia Elétrica, pelo interesse demonstrado no convênio do DINTER – UNESP – IFMT.

Aos meus filhos, Caio Victor Nunes e Gabriel Henrique Santos Nunes, agradeço pela torcida, pelo carinho e amor durante essa longa trajetória e, pela compreensão nesse longo tempo da minha ausência.

À minha esposa Eunice, pela paciência durante o curso e por ter cuidado dos nossos filhos enquanto estive ausente.

A todos os professores, funcionários da UNESP - Ilha Solteira e aos colegas do Laboratório de Sistemas Inteligentes (SINTEL), que direta ou indiretamente contribuíram para a realização deste trabalho.

Um agradecimento especial ao Prof. Dr Rubén Romero Lázaro e ao colega de IFMT, Prof. Dr. Tony Inácio da Silva, coordenadores do DINTER UNESP-IFMT, que nos deram essa oportunidade e acreditaram que conseguiríamos concluir o doutorado.

À Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES).

À ONF Brasil e a Peugeot por todo o apoio técnico na realização desta pesquisa e por nos disponibilizar a base de dados do inventário da fazenda São Nicolau.

Aos meus colegas de doutorado, em especial, à Valquíria, a quem sempre esteve presente nessa longa jornada, prestando auxílio em muitas ocasiões, e ao amigo Irênio, pelos bons conselhos e fortes orações, os meus sinceros agradecimentos.

Resumo

O aumento das emissões e concentrações de gás carbônico na atmosfera tem ocasionado a 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 gás 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, seja a curto, médio ou de longo prazo, o sequestro (absorção) de carbono em áreas de reflorestamento, em uma fazenda situada na Amazônia Mato-Grossense com 10 mil 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 realizando a previsão com maior acurácia e precisão da absorção de carbono, colaborando, desta forma, para que se adotem medidas para minimizar os impactos futuros do aumento da temperatura global e garantir a sustentabilidade do planeta. 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. Sustentabilidade do planeta.

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, whether in the short, medium or long term, the carbon sequestration in reforestation areas, on a 10000 hectare farm located in the Amazon region of Mato Grosso-Brazil. 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, thus contributing to the adoption of measures to minimize the impacts of future global temperature increase and ensure the sustainability of the planet, 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. Sustainability of the planet.

LISTA DE FIGURAS

Figura 1 - Representação de um Neurônio Artificial.	24
Figura 2 - Rede Feedforward com uma Única Camada.	24
Figura 3 - Rede Feedforward com uma Camada Intermediária.	25
Figura 4 - Rede Neural Recorrente.	25
Figura 5 - Perceptron Multicamadas.	28
Figura 6 - Algoritmo Retropropagação – Adaptação dos Pesos.	33
Figura 7 - Classificação das Redes da Família ART quanto à Aprendizagem.	35
Figura 8 - Estrutura de uma Rede ART- Fuzzy.	36
Figura 9 - Fluxograma da Rede Neural ART-Fuzzy.	41
Figura 10- Localização da Fazenda São Nicolau.	42
Figura 11 - Divisão da Fazenda por Talhão.	43
Figura 12 - Mudanças de Espécies Arbóreas para o Reflorestamento.	44
Figura 16 – Representação do DAP na Árvore.	46
Figura 13 - Dados do Talhão 1.	47
Figura 14 - Dados do Talhão 2.	48
Figura 15 - Dados do Talhão 4.	49
Figura 17 - Sistema Neural ART-Fuzzy-BP.	52
Figura 18 - Processamento da Rede Neural ART-Fuzzy.	55
Figura 19 - Processamento da Rede Neural ART-Fuzzy-BP.	58
Figura 20 - Desflorestamento - Amazônia Legal.	60
Figura 21 - Representação do Processo da Fotossíntese.	63
Figura 22 - Ciclo do Carbono.	65
Figura 23 - Anomalias da Temperatura Global – 1981-2010.	66
Figura 24 - Temperatura Global.	68
Figura 25 - Evolução Anual Global do CO ₂	69
Figura 26- Evolução Mensal Global do CO ₂ por Décadas.	69
Figura 27 - Representação do Deslocamento da Janela.	73
Figura 28 - Representação Gráfica da Previsão do CA _m do Talhão 1.	76
Figura 29 - Representação Gráfica da Previsão do CA _m da Teca no Talhão 1.	76
Figura 30 - Representação Gráfica da Previsão do CA _m do Parica no Talhão 1.	77
Figura 31 - Representação Gráfica da Previsão do CA _m do Cajá no Talhão 1.	77

Figura 32 - Representação Gráfica da Previsão do CA _m do Talhão 2.	78
Figura 33 - Representação Gráfica da Previsão do CA _m da Teca no Talhão 2.	79
Figura 34 - Representação Gráfica da Previsão do CA _m do Parica no Talhão 2.....	79
Figura 35 - Representação Gráfica da previsão do CA _m do Cajá no Talhão 2.....	80
Figura 36 - Representação Gráfica da previsão do CA _m no Talhão 4.	81
Figura 37 - Representação Gráfica da Previsão do CA _m da Teca no Talhão 4.	81
Figura 38 - Representação Gráfica da Previsão do CA _m da Parica no Talhão 4.	82
Figura 39 - Representação Gráfica da previsão do CA _m do Cajá no Talhão 4.....	82

LISTA DE TABELAS

Tabela 1 - Equipamentos e Variáveis Usadas para o Sistema de Monitoração da Fotossíntese na Folha do Jatobá.	18
Tabela 2 - Classificação das RNA quanto à Arquitetura e ao Algoritmo de Aprendizagem. .	27
Tabela 3 - Síntese das Variáveis do Inventário Florestal.	45
Tabela 4 - Grandezas Invariantes no Tempo.	51
Tabela 5 - Representação dos Talhões.	54
Tabela 6 - Parâmetros Fase de Treinamento.	55
Tabela 7 - Representação Binária das Grandezas Invariantes do Tempo.	56
Tabela 8 - Representação das Grandezas Variantes do Tempo.	57
Tabela 9 - Taxas Anuais de Desflorestamento em km^2	60
Tabela 10 - Focos de Monitoramento de Queimadas Detectadas no Brasil- km^2	61
Tabela 11 - Registro de Anomalias do Clima.	67
Tabela 12 - Especificações dos Parametros da Rede ART-Fuzzy.	74
Tabela 13 - Especificações dos Parametros da Rede MLP.	74
Tabela 14 - Resultados Obtidos do Erro Máximo e do MAPE do Talhão 1.	75
Tabela 15 - Resultados obtidos do Erro Máximo e do MAPE do Talhão 2.	78
Tabela 16 - Resultados obtidos do Erro Máximo e do MAPE.	80
Tabela 17 - Comparação dos Resultados Obtidos entre os Talhões.	83

LISTA DE ABREVIATURAS E SIGLAS

CO ₂	:	Gás Carbônico
GEE	:	Gases de Efeito Estufa
H ₂ O	:	Fórmula Química da Água
MDL	:	Mecanismo de Desenvolvimento Limpo
RNA	:	Redes Neurais Artificiais
BP	:	Rede Neural com Algoritmo de Treinamento <i>Backpropagation</i>
DAP	:	Diâmetro do tronco da árvore à altura de, aproximadamente, 1,30 m (um metro e trinta centímetros)
H	:	Altura da Árvore
CAP	:	Circunferência à Altura do Peito
RPPN	:	Reserva Particular do Patrimônio Natural
SAF	:	Sistema Agroflorestal
ONF	:	Serviço Florestal Nacional da França
PNI	:	Pró-Natura Internacional
AP	:	Árvore Padrão
DAPm	:	DAP da Árvore Padrão
DAPk	:	DAP da K-ésima Espécie das Árvores
N	:	Número de Árvores
NT	:	Número do Talhão
IA	:	Identificação da Árvore
NC	:	Espécie ou Nome Comum
CS	:	Característica do Solo
DT	:	Distância entre o Talhão e a Mata Ciliar
EA	:	Espaçamento entre as Árvores
QE	:	Quantidade de Espécies
CH ₄	:	Gás Metano
CFCS	:	Gás Clorofluorcarbono
O ₂	:	Gás Oxigênio
ATP	:	Molécula de Energia - Adenosina Trifosfato
NADP	:	Nicotinamida Adenina Dinucleotídeo Fosfato
ADP	:	Adenina Dinucleotídeo Fosfato

MLP	:	Multilayer Perceptron
IPCC	:	Painel Intergovernamental de Mudanças Climáticas
ONU	:	Organização das Nações Unidas
PPM	:	Medida do Volume de CO ₂ em Partes por Milhão
ADALINE	:	<i>Adaptive Linear Neural Element</i>
ART	:	<i>Adaptive Resonance Theory</i>
LVQ	:	<i>Learning Vector Quantization</i>
RBF	:	<i>Radial Basis Function</i>
SOM	:	<i>Self-Organizing Map</i>
F0	:	Camada de Entrada
F1	:	Camada de Comparação
F2	:	Camada de Reconhecimento
α	:	Parâmetro de Escolha da Rede
β	:	Taxa de Treinamento da Rede
ρ	:	Parâmetro de Vigilância da Rede
γ	:	Parâmetro de Agente de Controle de Estabilidade da Rede
MAPE	:	Erro Percentual Absoluto Médio.

SUMÁRIO

1	INTRODUÇÃO	12
1.1	MOTIVAÇÃO	12
1.2	DEFINIÇÃO DO PROBLEMA	15
1.3	OBJETIVOS DESTA PESQUISA	16
1.4	ORGANIZAÇÃO DO TEXTO	17
2	REVISÃO BIBLIOGRÁFICA	18
2.1	REFERÊNCIAS RELACIONADAS À ANÁLISE E QUANTIFICAÇÃO DO FLUXO DE CO ₂ COM TÉCNICAS DE REDES NEURAIS ARTIFICIAIS	18
2.2	TRABALHOS NÃO RELACIONADOS AO EMPREGO DE REDES NEURAIS ARTIFICIAIS NA QUANTIFICAÇÃO DO SEQUESTRO DE GÁS CARBÔNICO	21
2.3	ARTIGOS RELACIONADOS AO ESTUDO DAS REDES NEURAIS ARTIFICIAIS	22
3	REDES NEURAIS ARTIFICIAIS	23
3.1	INTRODUÇÃO	23
3.2	ARQUITETURA DE REDES NEURAIS ARTIFICIAIS	24
3.3	A REGRA DE APRENDIZADO	26
3.4	REDES PERCEPTRON MULTICAMADAS	27
3.5	TREINAMENTO VIA USO DO ALGORITMO DE RETROPROPAGAÇÃO BACKPROPAGATION	28
3.6	REDES DA FAMÍLIA ART	34
3.7	REDE NEURAL ART-FUZZY	36
4	MATERIAIS E MÉTODOS	42
4.1	DEFINIÇÃO DA ÁREA DE ESTUDO	42
4.2	DESCRIÇÃO DO EXPERIMENTO	45
4.3	APLICAÇÃO DA REDE NEURAL ART-FUZZY-BP	54

5	SEQUESTRO E ARMAZENAMENTO DE CARBONO POR ESPÉCIES FLORESTAIS	59
5.1	GASES DE EFEITO ESTUFA (GEE)	59
5.2	O CARBONO E A FOTOSSÍNTESE NAS PLANTAS	62
5.3	O CICLO DO CARBONO E SUA EVOLUÇÃO	64
5.4	A EVOLUÇÃO DOS ÍNDICES DE GÁS CARBONO NA ATMOSFERA	66
5.5	O SEQUESTRO DE CARBONO PELAS FLORESTAS	70
6	RESULTADOS E DISCURSÃO	72
6.1	CRITÉRIOS DE AVALIAÇÃO DA REDE NEURAL ART-FUZZY-BP	72
6.2	PARÂMETROS UTILIZADOS NA REDE NEURAL ART-FUZZY-BP	74
6.3	ANÁLISE DOS RESULTADOS DA REDE NEURAL ART-FUZZY-BP	75
7	CONCLUSÕES E SUGESTÕES PARA TRABALHOS FUTUROS	84
7.1	CONCLUSÕES	84
7.2	SEGESTÕES PARA TRABALHOS FUTUROS	85
	REFERÊNCIAS	86
	APÊNDICE – PUBLICAÇÕES DO AUTOR	91
	ANEXO – AUTORIZAÇÃO DE USO DA BASE DE DADOS.	92

1 INTRODUÇÃO

1.1 MOTIVAÇÃO

Nos últimos anos, o aumento das emissões e concentrações de gás carbônico na atmosfera, devido ao desmatamento desenfreado, às mudanças no uso da terra e a 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.

Tal situação gerou inquietação e preocupação, tanto nos representantes do poder público, quanto na comunidade científica, culminando na realização da Conferência de Kyoto, na cidade de Kyoto, no Japão, em dezembro de 1997, na qual foi aprovando um documento denominado Protocolo de Kyoto, que estipula metas de redução das emissões dos gases de efeito estufa (GEE) na atmosfera, principalmente o dióxido de carbono, pelos países industrializados (SISTER, 2007). Constitui-se em um instrumento de proteção ambiental e de luta contra as alterações climáticas. Neste Acordo foi estabelecida a proposta de criação da Convenção de Mudança Climática das Nações Unidas e as condições para sua implementação. Para entrar em vigor e se tornar obrigatório, foi necessário que mais de 55 países, que juntos, produzem 55% das emissões, o ratificassem, entrando em vigor em fevereiro de 2005, com compromissos mais rígidos para a redução da emissão dos gases que agravam o efeito estufa.

O Protocolo de Kyoto incorpora o comprometimento assumido pela maioria das nações industrializadas, que aderiram ao Protocolo, em reduzirem em 5%, em média, suas emissões de gases poluentes, com efeito de estufa, responsáveis pelo aquecimento global.

Um dos mecanismos estabelecidos pelo Protocolo, que possibilita a essas nações cumprirem com as exigências de redução de emissões de gases (GEE) fora de seus territórios, é o Mecanismo de Desenvolvimento Limpo - MDL (*Clean Development Mechanism*) (MICHAELOWA, 2005), que permite aos países industrializados adquirirem créditos de emissão de carbono (direitos de emissão), através do financiamento de medidas de redução das emissões em países em desenvolvimento, com o objetivo de apoiar o desenvolvimento sustentável.

Dentre tais medidas, estão o aumento da eficiência energética, o uso de fontes renováveis de energia, os projetos de florestamento e reflorestamento e o carbono limpo. De acordo com o MDL para que os projetos destinados à obtenção de reduções nas emissões de CO₂, através do sequestro de carbono, recebam os créditos de emissão de carbono comercializáveis eles devem produzir benefícios reais e mensuráveis em longo prazo.

Diante das exigências do Protocolo Kyoto e considerando que os países em desenvolvimento devem diminuir as emissões de gases poluentes a partir dos MDL's e do papel de sumidouro de CO₂, através das suas florestas, o Brasil se torna uma nação em potencial, dada a sua grande extensão territorial e o clima tropical favorável para o crescimento das árvores, para onde os países industrializados possam destinar recursos a título da aquisição dos créditos de carbono.

No contexto deste Protocolo, será importante abordar a questão da compensação ou créditos de carbono, incluindo estudos em áreas de florestas in natura ou reflorestamentos, como possibilidade de sumidouros de CO₂ ou sequestro de carbono, para o sucesso de qualquer sistema de comércio de emissão GEE. Para obter resultados satisfatórios e se possa colher benefícios econômicos e ambientais, em nível global, associados à mitigação desses gases, é necessário utilizar eficazmente o potencial florestal para diminuição de GEE (LEBLANC, 1999; SILVA, 2010).

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 em lavouras, práticas do manejo do solo, adoção de sistemas florestais e manejo da floresta. Estes últimos garantem o reflorestamento de áreas já desmatadas, contribuindo assim para conter o desmatamento ilegal de grande parte das florestas brasileiras, que é uma questão de grande importância com reflexos no ciclo do carbono.

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 (2011).

A prática do florestamento e do reflorestamento 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. Porém, para isso faz-se necessário que o fluxo resultante da emissão e captação de CO₂ da atmosfera seja metodologicamente aferido e com significativo grau de confiabilidade, de maneira que se pode inclusive prever o comportamento futuro.

O índice de emissão de carbono, no contexto global, é o aspecto preponderantemente responsável pelo efeito estufa e, conseqüentemente, pelo aquecimento global, colocando em risco a vida de todas as espécies de seres vivos existentes no planeta.

Desta maneira, torna-se imprescindível a adoção de medidas para a redução destes índices, visando à sustentabilidade ambiental e, também, o desenvolvimento de métodos eficientes para a quantificação das emissões e sequestro de CO₂ na atmosfera, ou seja, a quantificação do fluxo de carbono.

Dentre as medidas para redução de emissão de CO₂ está a manutenção da floresta nativa, o reflorestamento em áreas desmatadas, ou o plantio de árvores em outras áreas. Quanto aos métodos, para que se possa inferir de maneira fidedigna a real situação que se apresenta determinada área, considerada como poço de carbono, mensurando a quantidade de CO₂ resultante entre a emissão e absorção desse gás na atmosfera, faz-se necessário o desenvolvimento acurado de modelos de fluxo e trocas de CO₂.

1.2 DEFINIÇÃO DO PROBLEMA

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 Bender (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.

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*) (CARPENTER; GROSSBERG, 1987), a ART-Fuzzy segundo (CARPENTER; GROSSBERG, 1992) e uma rede neural feedforward multicamadas com treinamento executado via uso do algoritmo retropropagação (WERBOS, 1974). Esta rede composta é designada, nesta tese, como Rede Neural ART-Fuzzy-BP. A escolha por esta arquitetura foi em razão dela apresentar propriedades importantes e imprescindíveis à resolução ao problema-alvo desta pesquisa: predição do sequestro de carbono em área reflorestada. Ou seja, as redes neurais preservam duas propriedades fundamentais para o processamento da rede: a estabilidade (capacidade de aprender através do ajuste dos pesos) e a plasticidade (capacidade de continuar a aprender com a inclusão de novos padrões, sem perder a memória anteriormente adquirida). Estes dois atributos proporcionam à rede neural a aprendizagem estável e convergência rápida.

No que tange a pertinência científica o uso da Rede Neural ART-*Fuzzy*-BP, para a quantificação do sequestro de carbono em área de reflorestamento em nível de Brasil, constata-se que não existem trabalhos científicos que se utilizam dessa ferramenta no tema objeto do estudo, ou seja, quantificação do sequestro de carbono, de grande relevância para a sustentabilidade do planeta e suas espécies.

1.3 OBJETIVOS DESTA PESQUISA

Este trabalho 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.

Para atingir tal objetivo as seguintes metas foram definidas:

- a) analisar os dados de fatores ambientais e fluxo de carbono, coletados manualmente de um inventário florestal;
- b) selecionar, relacionar e correlacionar os fatores mais relevantes para compor o banco de dados das amostras de entrada e saída da rede neural. Esta fase corresponde ao pré-processamento de dados para uso da rede neural;
- c) definir e projetar a arquitetura da rede neural;
- d) preparar e codificar os conjuntos de dados para treinamento e teste da rede neural;
- e) treinar, testar e validar a rede neural;
- f) analisar os resultados obtidos com o desenvolvimento e construção do sistema proposto.

1.4 ORGANIZAÇÃO DO TEXTO

Este trabalho está dividido em sete capítulos incluindo a Introdução e um apêndice.

O primeiro capítulo é introdutório apresentando a motivação, definição do problema estudado e seus objetivos.

No capítulo 2 será apresentado uma revisão bibliográfica sobre as pesquisas já desenvolvidas voltadas para o sequestro de carbono, utilizando técnicas de redes neurais artificiais.

No capítulo 3 são apresentadas as teorias relacionadas ao estudo das redes neurais artificiais, enfatizando o estudo da 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.

No capítulo 4 apresenta a definição da área a ser estudada, com a descrição do experimento para se predizer e quantificar, seja a curto, médio ou de longo prazo, a absorção de carbono na atmosfera.

No capítulo 5 são abordados os principais gases de efeito estufa, o ciclo do carbono e sua evolução, os índices de desmatamento e poluição na atmosfera e o processo de absorção de carbono pelas árvores.

No capítulo 6 apresenta-se os critérios, parâmetros e a análise dos resultados da rede ART-Fuzzy-BP.

No capítulo 7 são apresentadas as conclusões finais e as propostas para trabalhos futuros.

No Apêndice, são relacionados os artigos que foram publicados durante a fase de desenvolvimento da presente pesquisa e, como anexo, apresenta-se a autorização de uso da base de dados do inventário florestal da área reflorestada.

2 REVISÃO BIBLIOGRÁFICA

2.1 REFERÊNCIAS RELACIONADAS À ANÁLISE E QUANTIFICAÇÃO DO FLUXO DE CO₂ COM TÉCNICAS DE REDES NEURAIS ARTIFICIAIS

Ressalta-se que na literatura, existem poucas referências que tratam da análise e quantificação do fluxo de carbono, enquanto mecanismo de desenvolvimento limpo (MDL), através do emprego de redes neurais artificiais.

Como subsídio para esta pesquisa, com relação à quantificação do sequestro de carbono, utilizando técnicas de redes neurais artificiais, destaca-se a pesquisa precursora (PUENTE DE LA VEGA, 2003) nesta área de estudo. Nesta pesquisa, foi desenvolvido um estudo onde foram realizadas coletas de dados na folha do Jatobá, durante um ano, duas vezes por semana, gerando arquivos através de um medidor de fotossíntese portátil, um fluorômetro e um medidor de área foliar com medidas diárias e, posteriormente, com medidas a cada estação do ano, sobre o método de modelagem de fotossíntese, no nível da folha do jatobá (*Hymenaea courbaril* L.), utilizando uma rede neural feedforward com a técnica de treinamento de retropropagação, ou simplesmente, rede neural *backpropagation* (BP) (WERBOS, 1974), como um passo inicial para a quantificação do potencial de gás carbônico nas plantas. Esses equipamentos são demonstrados na Tabela 1.

Tabela 1 - Equipamentos e Variáveis Usadas para o Sistema de Monitoração da Fotossíntese na Folha do Jatobá.

Equipamentos	Variáveis	Fabricante
Sistema de medida de fotossíntese portátil	- Fotossíntese líquida - Taxa de transpiração - Condutância estomática - Umidade relativa do ar e da câmara - Radiação fotossintética ativa - Temperatura da folha e do ar - Concentração de CO₂ do ar/câmara	LI - COR LI – 6400
Fluorômetro	- Fluorescência	OPTI - SCIENCES OS5-FL
Medidor de área Foliar	- Área Foliar	LI COR LI 3000 A

Fonte: Elaboração do autor

Algumas variáveis foram utilizadas, variando o número de neurônios da entrada RNA, sendo as mais importantes: temperatura da folha (T_{fol}), radiação fotossinteticamente ativa dentro (PARi) e fora da câmara (PARo), temperatura do ar (T_{ar}), umidade relativa do ar (U_{miar}) e da câmara ($U_{micâ}$), concentração de CO_2 do ar (CO_{2ar}) e da câmara ($CO_{2câ}$), tempo (instante de medida), planta (plântula na qual foi realizada a medida) e estação do ano (Est). Segundo Puente De La Vega (2003) pela grande quantidade de dados medidos durante um ano, referentes às quatro estações, e pela grande quantidade de treinamentos realizados, variando a estrutura da rede e os parâmetros de treinamento, o objetivo de modelar a fotossíntese nessa pesquisa foi atingido.

Esse trabalho teve como principal objetivo utilizar imagens de satélite, através de mapas temáticos em Floresta Densa, para obter estimativas em relação à quantidade de CO_2 armazenado e da biomassa arbórea. Na primeira etapa do levantamento as informações foram medidas e identificadas com 48 amostras de espécies arbóreas que apresentavam diâmetro a 1,30 metros do solo (DAP). Na segunda etapa foram abatidas, pesadas e mensuradas 219 árvores, com base nos resultados do inventário florestal para identificar e determinar a quantidade de carbono armazenado e a sua biomassa arbórea. Foi utilizada para esta pesquisa uma rede neural multicamada com aprendizado de retropropagação. Com todas essas informações puderam verificar e confirmar, através da pesquisa proposta, que a aplicação de técnicas de Redes Neurais Artificiais mostrou-se promissora e efetiva na obtenção de estimativas na quantidade de carbono armazenado e da biomassa arbórea (SCHOENINGER, 2008).

(QI et al., 2010) desenvolveram um estudo referente à análise da relação do fluxo de carbono (FC) com alguns fatores ambientais, tais como a temperatura do ar (TA), temperatura do solo (TS), umidade relativa do ar (RH), utilizando um modelo de predição com base na rede *Wavelet* (DAUBECHIES, 1992) e, posteriormente, o modelo foi comparado com a rede neural BP e a máquina de vetor de suporte (SVM) (HAYKIN, 2008), levando em consideração a estrutura de rede, a precisão, a taxa de convergência, e assim por diante. Os resultados experimentais mostraram que a rede *Wavelet* é mais estável e precisa, e pode obter maior taxa de convergência.

Mehdawi e Silveira (2012) desenvolveu um estudo, na Malásia, objetivando realizar estimativas quanto as incertezas nas emissões de gases de efeito estufa, em especial, do gás carbônico, através do uso de técnicas de redes neurais artificiais e sensoriamento remoto.

Este estudo em escala global e regional, para observar e monitorar mudanças nas copas das árvores das florestas, que já tinham passado por processos de desmatamento, realizando uma comparação com imagens originais de uma região onde existiam várias espécies de árvores e, da mesma área, agora já urbanizada. Com o uso das técnicas de redes neurais artificiais alcançou-se nesta pesquisa um resultado com a precisão de acertos de quase 96,55%.

Almeida et al. (2009) desenvolveram um trabalho propondo uma metodologia integrada, a partir de imagens de satélite, que estimasse o potencial energético de biomassa florestal na região amazônica, utilizando técnicas de redes neurais para extrair informações sobre a biomassa e inseri-las em um sistema de informações geográficas (SIG). Para a segmentação e classificação das imagens foram usadas as redes neurais de Kohonen (1990) e, a rede RBF (função de base radial) para fazer a aproximação funcional entre os volumes de biomassa observados em campo e o mapeamento entre os níveis de refletância de energia eletromagnética. De acordo com os autores, a principal desvantagem nessa pesquisa, para a confiabilidade dos resultados, refere-se à necessidade de medições em campo para compor a base de dados, ainda que os custos serem bem mais baixos quando se trabalha com imagens de satélites, considerando a densa floresta e a topografia da região em pesquisa.

2.2 TRABALHOS NÃO RELACIONADOS AO EMPREGO DE REDES NEURAIAS ARTIFICIAIS NA QUANTIFICAÇÃO DO SEQUESTRO DE GÁS CARBÔNICO

Com relação ao MDL, encontrou-se uma pesquisa que apresenta, de maneira integrada e crítica, a análise dos primeiros projetos de sequestro de carbono no Brasil.

Nesse estudo, foram apresentadas as vantagens e desvantagens do sequestro de carbono, enquanto instrumento de mitigação das mudanças climáticas, bem como a sua contribuição para o desenvolvimento sustentável, seus limites e oportunidades enquanto mecanismo de desenvolvimento limpo no território brasileiro e, ainda, uma reflexão sobre a contribuição do sequestro de carbono para o desenvolvimento sustentável, enfatizando as diferentes interpretações e importância de projetos para esse fim, das questões da participação social, de políticas de gestão ambiental, da responsabilidade social e ambiental das empresas (MAN YU, 2004).

Saathi et al. (2006) desenvolveram um estudo para mapear a distribuição da biomassa na floresta amazônica com dados coletados por sensoriamento remoto com o objetivo de medir o fluxo de carbono na região. Utilizaram para isso cerca de 500 medições em diferentes áreas da Bacia Amazônica. Eles conseguiram estimar a quantidade total de carbono na floresta com uma margem de erro de aproximadamente 20%, incluindo não somente a biomassa acima do solo, mas também sob o solo. Para esse estudo optaram por escolher métodos estatísticos de correlação entre as medições feita no campo e os dados de sensoriamento remoto, ao invés de utilizarem técnicas de redes neurais artificiais.

Soares et al. (2005) desenvolveram uma pesquisa que tinha por objetivo ajustar equações para estimar o carbono presente no fuste das espécies de árvores de *Eucalyptus grandis* e a quantidade de estoque de carbono, com idade entre 32 e 80 meses. Foram selecionadas e medidas a altura total e o DAP (Diâmetro com casca a 1,30 m do solo) de 532 espécies para o ajuste das equações. Ainda, forneceram as estimativas de biomassa da madeira e casca do fuste, através da retirada de discos e casca da madeira encontrando a densidade básica. Verificaram que as equações se ajustaram bem aos dados observados após a análise dos coeficientes e da determinação das equações, para estimar o carbono total no fuste e o carbono da madeira, com o nível de probabilidade chegando a 95% em relação à escolha dos coeficientes significativos.

2.3 ARTIGOS RELACIONADOS AO ESTUDO DAS REDES NEURAIIS ARTIFICIAIS

Para o desenvolvimento do sistema de predição de quantificação do sequestro de carbono, obtida através da extração das características e utilizando uma das técnicas da inteligência artificial, as redes neurais artificiais e, mais especificamente, a rede neural *ART-Fuzzy* e a rede neural *feedforward* multicamadas com treinamento executado via uso do algoritmo retropropagação.

Ferramentas estas capazes de lidar com dados complexos e não-lineares, apresentando rapidez de resposta. Nesse contexto, percorreram-se os artigos que abordavam essas redes neurais:

- CARPENTER, G. A. and GROSSBERG, S. A Self-organizing neural network for supervised learning, recognition and prediction. *IEEE Communications Magazine*, New York, v. 30, n. 9, p. 38-49, 1992.
- CARPENTER, G. A.; GROSSBERG, S.; MARKUZON, N.; REYNOLDS, J. H. and ROSEN, D. B. Fuzzy ARTMAP: a neural network architecture for incremental supervised learning of analog multidimensional maps. *IEEE Transactions on Neural Networks*, v. 3, n. 5, p. 698-713, 1992. .
- CARPENTER, G. A.; GROSSBERG, S.; ROSEN, D.B. Fuzzy ART: fast stable learning and categorization of analog patterns by an adaptive resonance theory., *Neural Networks*, New York, v. 4, p. 759-771, 1991.
- BASHEER, I.A.; HAJMEER, M. Artificial neural networks: fundamentals, computing, design, and application. *J. Microbiol. Methods* 43 (2000) 3-31.
- WIDROW, B.; LEHR, M. 30 years of adaptive neural networks: perceptron, madaline and backpropagation. *Proceedings of IEEE Neural Networks Congress*, v. 78, n.. 9, p. 1415-1442, 1990.


3 REDES NEURAIS ARTIFICIAIS

3.1 INTRODUÇÃO

Uma possibilidade exequível para representar situações de não-linearidade, complexidade e variabilidade é a utilização de Redes Neurais Artificiais (RNAs) segundo Bender (1996), um dos diversos paradigmas da Inteligência Artificial encontrado em Haykin (2008). As Redes Neurais são, basicamente, modelos matemáticos que utilizam técnicas computacionais que se inspiram na forma com que o cérebro interpreta as informações e adquirem conhecimento por meio de experiências obtidas (MINUSSI, 2007). Com isso, possuem considerável capacidade computacional de aprendizado e de generalização. Essa característica permite o desenvolvimento de sistemas capazes de lidar com dados imperfeitos, ausentes ou ruidosos e, ainda, manter o resultado esperado.

Em analogia ao neurônio biológico, as redes neurais são compostas por neurônios (elementos de processamento), dispostos em camadas, interligados através de conexões (sinapses), que agregam pesos atribuídos a cada uma das conexões, onde se armazena todo o conhecimento de uma rede neural. As Redes Neurais possuem uma camada de entrada, onde os sinais são captados pelos neurônios e multiplicados aos seus respectivos pesos sinápticos, combinam estes sinais e produzem um valor de atividade como sendo a soma das entradas pelos seus pesos associados, resultando em uma saída linear. Logo após, é aplicada uma função de ativação para restringir a amplitude da saída do neurônio, quais sejam: função degrau, bipolar ou rampa simétrica ou função linear, sigmoidal ou gaussiana (funções totalmente diferenciáveis), resultando no valor de saída do neurônio, conforme ilustrado na Figura 1.

Figura 1 - Representação de um Neurônio Artificial.




Fonte: Haykin (2008)

3.2 ARQUITETURA DE REDES NEURAIS ARTIFICIAIS

A arquitetura da rede neural é definida, em função da organização e disposição dos neurônios entre si, através da direção das conexões sinápticas. Sendo, basicamente, três diferentes tipos de arquiteturas:

Redes *feedforward* de uma única camada – são consideradas mais simples no qual todas as sinapses estão interligadas somente aos neurônios da camada seguinte, propagando os sinais de entrada para a próxima camada. Portanto, rigorosamente alimentada adiante ou acíclica, exemplificada pela Figura 2.


Figura 2 - Rede Feedforward com uma Única Camada.



Fonte: Haykin (2008)

Redes *feedforward* de múltiplas camadas - além de ter a camada de entrada e de saída, também possui uma ou mais camadas intermediárias, onde os neurônios de cada uma das camadas possuem como entrada a saída do neurônio da próxima camada, sendo alimentada sempre para frente, conforme ilustrado na Figura 3.


Figura 3 - Rede Feedforward com uma Camada Intermediária.



Fonte: Haykin (2008)

Redes Recorrentes - há sinapses com os neurônios da mesma camada (*feed-lateral*) ou com os da camada anterior (*feed-back*), tendo pelo menos um ciclo, realimentando à saída de neurônios para os demais neurônios da rede, conforme representado na Figura 4.

Figura 4 - Rede Neural Recorrente.



Fonte: Haykin (2008)

As composições estruturais de uma rede, quanto ao número de neurônios em cada camada e a função de ativação de cada neurônio, após definida sua arquitetura, diz respeito à topologia da rede neural.

3.3 A REGRA DE APRENDIZADO

Uma das habilidades mais importantes das redes neurais é a capacidade de aprender a partir de um conjunto de dados, extraindo o conhecimento para encontrar soluções para novos padrões da rede, melhorando com isso o seu desempenho.

O aprendizado é realizado através de um processo de ajuste dos pesos sinápticos, conhecido como treinamento da rede. O treinamento tem como objetivo fazer com que um conjunto de padrões de entrada produza um conjunto de saídas desejadas, ou seja, saídas previamente conhecidas, de acordo com Haykin (2008).

Os principais modelos de processos de treinamento e aprendizagem (HAYKIN, 1994), em redes neurais, de forma geral podem ser classificados em:

- a. aprendizado supervisionado - a rede é treinada através da combinação dos pares de treinamento apresentados à rede, representando os vetores de entrada de cada amostra, com o conhecimento prévio das suas correspondentes saídas desejadas, sendo monitorado pela existência de um “professor” externo a rede;
- b. aprendizado não-supervisionado - a rede é treinada usando apenas os próprios dados do vetor de entrada, sem que se empregue um agente externo (professor). Através do processo de auto-organização, ajustam-se os pesos entre os seus elementos obtido apenas com base nos dados de entrada, com a inexistência dos respectivos resultados de saída, organizando os dados apresentados e descobrindo as suas propriedades coletivas, característica esta conhecida como plasticidade;
- c. aprendizado por reforço - o conjunto de treinamento é formado somente pelos dados de entrada. Porém, existe um elemento externo que retorna um sinal de reforço ou de penalidade, ao invés de retornar o valor do erro de saída da rede neural.

Para que as redes neurais possam aprender existem diversos algoritmos de treinamento para efetuar essa aprendizagem, destacando-se, dentre eles: Regra delta de Widrow, Regra delta generalizada, Regra de Hebb, e Hoff, e algoritmo de aprendizagem Retropropagação, diferenciando-se pela forma como os pesos são ajustados e os métodos usados para minimizar o erro.

Existem diversos modelos de Redes Neurais, destacando-se os mais conhecidos: ADALINE (*Adaptive Linear Neural Element*), ART (*Adaptive Resonance Theory*), Máquinas Boltzmann (*Boltzmann Machine*), Máquinas Cauchy (*Cauchy Machine*). Rede Hopfield, LVQ (*Learning Vector Quantization*), Perceptron, RBF (*Radial Basis Function*), RNN (*Recurrent Neural Network*), SOM (*Self-Organizing Map*), apresentados sucintamente na Tabela 2.

Tabela 2 - Classificação das RNA quanto à Arquitetura e ao Algoritmo de Aprendizagem.


		Algoritmos de Aprendizagem			
		Gradiente Descendente	Hebbiano	Competitivo	Estocástico
Tipos de Arquitetura das Redes Neurais	Redes <i>feedforward</i> de única camada	ADALINE Hopfield Perceptron	Hopfield	LVQ SOM	
	Redes <i>feedforward</i> de múltiplas camadas	RBF Perceptron			
	Redes Recorrentes	RNN	Hopfield	Família ART	Máquinas Boltzmann e Cauchy

Fonte: Elaboração do autor

3.4 REDES PERCEPTRON MULTICAMADAS

A rede neural *Perceptron* Multicamadas, ou simplesmente MLP (*Multilayer Perceptron*), é um dos modelos de redes neurais mais utilizados e, tem sido aplicado com grande sucesso na resolução de problemas complexos e de natureza diversa. São redes com treinamento efetuado de forma supervisionada e são caracterizadas por constituírem uma camada de entrada, pela existência de ao menos uma camada intermediária, e uma camada de saída, sendo ilustrada na Figura 5.

Figura 5 - Perceptron Multicamadas.



Fonte: Haykin (2008)

A rede *Perceptron Multicamadas* é treinada com o algoritmo retropropagação (*backpropagation*) (WERBOS,1974). Este treinamento possui duas fases, sendo elas: a fase *forward* e a fase *backward*. Na fase *forward* o sinal na rede é propagado da camada de entrada até a camada de saída da rede e sempre para frente.

Na fase *backward*, atualizam-se os pesos dos neurônios da camada de saída em direção à camada de entrada.

3.5 TREINAMENTO VIA USO DO ALGORITMO DE RETROPROPAGAÇÃO BACKPROPAGATION

O treinamento é realizado de maneira supervisionada, iniciado pela apresentação de um padrão de entrada do vetor $\mathbf{x}$ à rede neural, propagando-se para as camadas seguintes, até a camada de saída, onde finalmente será produzida uma saída $\mathbf{y}$. Após este procedimento, será calculado o erro de cada saída da rede denotado pela diferença entre saída desejada e a saída da rede.

A partir desse momento, o erro será retropropagado, no sentido inverso, para as camadas intermediárias até a camada de entrada, adaptando-se os pesos das conexões intermediárias, associado à derivada parcial do erro quadrático, para cada elemento com relação aos pesos e, finalmente, os pesos serão ajustados para cada elemento.

Um novo padrão é apresentado a rede, repetindo o processo para todos os padrões, até que ocorra a total convergência, quando o $(|\text{erro}| \leq \text{tolerância estabelecida})$, dado por Werbos (1974).

O algoritmo de retropropagação é baseado no método do gradiente descendente (WASSERMAN, 1989), com adaptação de pesos baseada na minimização dos erros quadráticos. Em primeiro momento, os pesos recebem valores aleatórios do intervalo $\{0,1\}$ e a soma dos erros quadráticos de cada neurônio da camada de saída definido por Widrow e Lehr (1990).

O algoritmo de retropropagação consiste na adaptação de pesos, que inicialmente são adotados como valores aleatórios do intervalo $\{0,1\}$, baseado no propósito de minimizar os erros quadráticos. A soma do erro quadrático de cada neurônio será alocado na camada de saída da rede neural, é dada por Lopes et al. (2005).

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

sendo:

ε_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.

O ajuste dos pesos será obtido considerando-se o neurônio de índice i da rede neural, e utilizando-se o método do gradiente descendente, conforme Haykin (2008) e Widrow (1990):

$$V_i(h + 1) = V_i(h) + \theta_i(h) \quad (2)$$

sendo:

$$\theta_i(h) = -\gamma [\nabla_i(h)] \quad (3)$$

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 ;

V_i : vetor contendo os pesos do neurônio i

sendo:

$$V_i = [w_{0i} \ w_{1i} \ w_{2i} \ \dots \ w_{ni}]^T.$$

A direção adotada, conforme a equação (2), para minimizar a função objetivo do erro quadrático, corresponde à direção contrária ao vetor-gradiente. O comprimento do vetor $\nabla_i(h)$ é determinado pelo parâmetro γ .

As equações (4) e (5) definem a função sigmoide, definida por Haykin (2008) e Widrow e Lehr (1990):

$$y_i = \frac{1 - \exp(\lambda s_i)}{1 + \exp(\lambda s_i)} \quad (4)$$

ou

$$y_i = \frac{1}{1 + \exp(\lambda s_i)} \quad (5)$$

sendo:

λ : constante que determina a inclinação da curva y_i .

Os valores do espectro de variação da função sigmoide y_i são respectivamente, $[0, +1]$ ou $[-1, +1]$, dados pela equação (4) ou (5).

Uma formulação bastante interessante é o algoritmo retropropagação com momento, de acordo com Widrow e Lehr (1990).

$$V_{ij}(h+1) = V_{ij}(h) + \Delta V_{ij}(h) \quad (6)$$

sendo:

$$\Delta V_{ij}(h) = 2\gamma(1 - \eta)\delta_i(h)X_j + \eta\Delta V_{ij}(h-1) \quad (7)$$

V_{ij} : peso sináptico de interligação entre os neurônios i e j ;

η : constante de momento, $0 < \eta < 1$;

δ_i : derivada do erro quadrático (gradiente);

X : vetor de entrada.

Os modos de treinamento podem ser de dois tipos, o chamado sequencial, em que o ajuste dos pesos é efetuado após a apresentação de cada padrão e, o lote com todos os padrões ao mesmo tempo. Obtem-se o esquema de adaptação de pesos (WIDROW; LEHR, 1990), considerando-se a função sigmoide e o termo momento.

$$V_{ij}(h+1) = V_{ij}(h) + \Delta V_{ij}(h) \quad (8)$$

sendo:

$$\Delta V_{ij}(h) = 2\gamma(1 - \eta)\beta_j x_i + \eta\Delta V_{ij}(h-1) \quad (9)$$

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

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

$$\beta_j = \sigma_j \varepsilon_j \quad (10)$$

sendo:

σ_j : derivada da função sigmoide dada pela equação (4) ou (5), respectivamente, com relação a s_j :

$$\sigma_j = 0,5 \lambda (1 - y_j^2) \quad (11)$$

$$\sigma_j = \lambda y_j (1 - y_j) \quad (12)$$

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


$$\beta_j = \sigma_j \sum_{k \in R(j)} w_{jk} \beta_k \quad (13)$$

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 .

Como agente de controle da estabilidade do processo iterativo temos o parâmetro γ . Serão inicializados aleatoriamente os pesos da rede, considerando o intervalo $[0,1]$ (WIDROW, 1990).

Figura 6 - Algoritmo Retropropagação – Adaptação dos Pesos.



Fonte: Altran (2010)

3.6 REDES DA FAMÍLIA ART

Teoria da Ressonância Adaptativa (ART)

Este modelo compõe um conjunto de redes neurais da Família ART. Foi desenvolvido, em 1976, por Stephen Grossberg (CARPENTER; GROSSBERG, 1987), como uma teoria do processamento de informações cognitivas humanas, baseada na fisiologia do sistema nervoso.

Os sistemas de redes neurais da família ART podem se auto-organizar, em tempo real, produzindo categorias de reconhecimento estável.

São considerados plásticos por serem capazes de adaptar ou agrupar padrões de entrada em um ambiente em mudança. A plasticidade é a capacidade de preservarem seus conhecimentos aprendidos anteriormente, mantendo sua habilidade de aprender novos padrões, impedindo que outros novos padrões superponham ao prévio conhecimento adquirido pela rede neural. Por isso, as redes neurais artificiais da família ART são capazes de resolver os problemas de estabilidade e plasticidade.

A Família ART possui vários modelos de redes neurais, utilizando paradigmas de aprendizado classificados tanto quanto supervisionado e não-supervisionado, dentre eles, destacam-se:

ART1 (1987): a mais simples das Redes ART, utilizando treinamento não-supervisionado, tendo como entrada da rede apenas dados binários (CARPENTER; GROSSBERG, 1987).

ART2 (1987): utilizando também treinamento não-supervisionado, podendo também ser utilizada para dados binários, suportando entradas contínuas (CARPENTER; GROSSBERG, 1991).


ART3 (1990): é o refinamento da ART1 e ART2, modelo também não-supervisionado e, considera a ação dos neurotransmissores em propagar os dados pela rede, através do mecanismo conhecido por sinapse (CARPENTER; GROSSBERG, 1990).

ART Fuzzy (1987): nessa rede o treinamento é não-supervisionado e os cálculos são baseados na lógica nebulosa, com a capacidade de reconhecimento estável de auto-organização em resposta a padrões de entrada tanto em binários como analógicos (CARPENTER; GROSSBERG; ROSEN, 1991).

ARTMAP (1987): utiliza o treinamento supervisionado, combinando duas redes ART's, a ARTa e ARTb, no qual a primeira unidade recebe os dados de entrada, e a segunda unidade recebe os dados das saídas desejadas, com o objetivo a fazer o ajuste mínimo possível do parâmetro de vigilância na primeira unidade, a fim de fazer a classificação correta (CARPENTER; GROSSBERG; REYNOLDS, 1991).

A Família ART possui vários modelos de redes neurais, classificados tanto quanto supervisionado e não-supervisionado conforme iustrado na Figura 7.

Figura 7 - Classificação das Redes da Família ART quanto à Aprendizagem.




Fonte: Elaboração do autor

Para o treinamento das Redes Neurais da Família ART existem dois métodos de treinamento, sendo eles, o método de treinamento rápido, que atualiza os pesos usando equações algébricas, e o método de treinamento lento, que usa equações diferenciais para fazer o ajuste dos pesos.

3.7 REDE NEURAL ART-FUZZY

A rede neural ART é composta por três camadas: F0 (camada de entrada); F1 (camada de comparação); F2 (camada de reconhecimento) que armazena as categorias (*clusters*), conforme ilustrado na Figura 8.

Figura 8 - Estrutura de uma Rede ART- Fuzzy.



Fonte: Lopes (2005)

Os passos do algoritmo da rede neural ART Fuzzy (CARPENTER, 1991), serão descritos logo abaixo.

Passo1: Dados de Entrada

Os dados de entrada da rede neural são representados pelo vetor

$$\mathbf{a} = [a_1 \quad a_2 \quad a_3 \quad . \quad . \quad . \quad a_M].$$

Logo após, é feito a normalização do vetor para que seja evitado a proliferação de categorias, de acordo com equação (14).

$$\bar{\mathbf{a}} = \frac{\mathbf{a}}{|\mathbf{a}|}, \quad \text{sendo:} \quad |\mathbf{a}| = \sum_{i=1}^M a_i \quad (14)$$

onde :

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

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

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

Passo 2: Codificação do vetor de entrada

A codificação de complemento do vetor tem por finalidade preservar a amplitude da informação, cujo o procedimento é realizado de acordo com a equação (15).

$$\bar{a}_i^c = 1 - \bar{a}_i \quad (15)$$

logo:

$$\bar{\mathbf{a}}^c = [\bar{a}_1^c \quad \bar{a}_2^c \quad . \quad . \quad . \quad \bar{a}_M^c]$$

$\bar{a}_i^c$: elemento complementar do vetor de entrada normalizado;

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

Assim o vetor de entrada da rede poderá ser escrito por:

$$\mathbf{I} = [\bar{\mathbf{a}} \quad \bar{\mathbf{a}}^c] \quad (16)$$

$$\mathbf{I} = [\bar{a}_1 \quad \bar{a}_2 \quad . \quad . \quad . \quad \bar{a}_M \quad \bar{a}_1^c \quad \bar{a}_2^c \quad . \quad . \quad . \quad \bar{a}_M^c]$$

sendo:

$\mathbf{I}$: vetor de entrada da rede normalizado e com codificação de complemento

$$|\mathbf{I}| = \sum_{i=1}^M \bar{a}_i + \sum_{i=1}^M \bar{a}_i^c \quad (17)$$

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

Passo 3: Vetor de Atividade

O vetor de atividade de F2 é simbolizado por $\boldsymbol{\Omega} = [\Omega_1 \Omega_2 \dots \Omega_N]$, sendo N o número de categorias criadas em F2.

Deste modo, obde-se a regra escrita abaixo:

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

Passo 4: Parâmetros da Rede Neural

Para o processamento da rede ART-Fuzzy serão usados os seguintes parâmetros:

Parâmetro de escolha : O parâmetro $\alpha > 0$; responsável pela escolha das categorias;

Parâmetro de vigilância : O parâmetro $\rho \in [0,1]$; responsável pelo número de categorias criadas na camada F2 e, conseqüentemente, pela capacidade de generalização da rede determinando quando cluster serão formados.

Se ρ é pequeno, a rede terá alta capacidade de generalização pois, poucas categorias são criadas, caso contrário, a rede possui baixa capacidade de generalização pois, muitas categorias são criadas.

Taxa de treinamento : $\beta \in [0,1]$ e é responsável pelo controle da velocidade e adaptação da rede , ou seja, responsável por regular a taxa de aprendizagem, onde quando $\beta = 0$ a aprendizagem é lenta e para o valor de $\beta = 1$, a aprendizagem torna-se rápida;

Passo 5: Inicialização dos Pesos

Todos os pesos inicialmente possuem valores iguais a 1, indicando que não existe nenhuma categoria ativa, conforme a equação (18):

$$W_{j1}(0) = \dots = W_{j2M}(0) = 1 \quad (18)$$

Passo 6: Escolha da Categoria

Considerando o vetor de entrada $\mathbf{I}$ em F1, para cada nó j em F2, atendendo a função de escolha T_j , determinada pela equação (19).

$$T_j(\mathbf{I}) = \frac{\mathbf{I} \wedge \mathbf{w}_j}{\alpha + |\mathbf{w}_j|} \quad (19)$$

sendo:

$\wedge$: o sinal de operador AND *fuzzy*, definido por: $(\mathbf{I} \wedge \mathbf{w})_i = \min(I_i, w_i)$

A categoria é escolhida pelo sistema associada ao nó J ativo, onde J irá representar o índice do neurônio vencedor, caso exista mais de uma categoria ativa, será escolhida a categoria a que possuir menor índice. A categoria escolhida J será descrita na equação (20):

$$J = \arg \{ \max T_j \}, j = 1, 2, \dots, N \quad (20)$$

Passo 7: Ressonância ou *Reset*

Caso o critério de vigilância seja satisfeito irá ocorrer a ressonância:

$$\frac{|\mathbf{I} \wedge \mathbf{w}_j|}{|\mathbf{I}|} \geq \rho \quad (21)$$

Caso o critério não seja satisfeito, de acordo com a equação (21), ocorre o dispositivo chamado *reset*, onde o nó J de $F2$ é excluído, adotando-se $T_j = 0$.

Então uma nova categoria será escolhida através da equação (20) para o processo de ressonância. Encontrando uma categoria que satisfaça, através da equação (21), esse procedimento será encerrado.

Passo 8: Atualização dos Pesos (Treinamento)

Ocorre então, a modificação do vetor dos pesos, após o vetor de entrada $\mathbf{I}$ ter completado o seu estado de ressonância e, conseqüentemente, ter ocorrido o aprendizado da rede, dado pela equação (22).

$$\mathbf{w}_j^{\text{nov}} = \beta (\mathbf{I} \wedge \mathbf{w}_j^{\text{velho}}) + (1 - \beta) \mathbf{w}_j^{\text{velho}} \quad (22)$$

onde :


J : representa a categoria ativa;

$\mathbf{w}_j^{\text{nov}}$: o vetor peso atualizado;

$\mathbf{w}_j^{\text{velho}}$: o vetor peso referente à atualização anterior.

O algoritmo da rede neural ART Fuzzy consiste no seguinte fluxograma, conforme ilustrado na Figura 9.

Figura 9 - Fluxograma da Rede Neural ART-Fuzzy.



Fonte: Lopes (2005).

4 MATERIAIS E MÉTODOS

4.1 DEFINIÇÃO DA ÁREA DE ESTUDO

A região estudada localiza-se na fazenda São Nicolau, adquirida em 1999 pela ONF Brasil Ltda., uma empresa brasileira, executora oficial do projeto de sequestro de carbono da Peugeot, que foi criada pelo serviço Florestal Nacional da França- (*Office National de Forêt - ONF*) em parceria com uma ONG franco-brasileira, a Pró-Natura Internacional (PNI), com o propósito fundamentalmente ambiental visando contribuir para amenizar os impactos nas emissões dos gases de efeito estufa (GEE).

A fazenda situa-se ao norte do Estado de Mato Grosso, conforme apresentado na Figura 10, 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 à margem esquerda do rio Juruena, com temperaturas variando entre 23° a 25°C, sendo mais elevadas durante as estações da primavera e verão, que são os períodos que mais chovem naquela região.

Figura 10- Localização da Fazenda São Nicolau.



Fonte: (ONF BRASIL, 2012)


Apresenta uma grande extensão de reserva de floresta amazônica Ombrófila Aberta e Densa, sendo constituída por Floresta, Floresta Estacional e Savana. Quanto ao relevo, está inserida no Planalto Apiacás-Sucurindi e Depressão Interplanáltica da Amazônia Meridional-Serra do Norte, Pecutinga e Moreru (RADAM, 1980).

Com uma área de 7.200 hectares, dos quais, 1800 hectares de Reserva Particular do Patrimônio Natural – RPPN, uma área de reflorestamento com quase 1962 hectares e, mais 972 hectares entre capoeira, pastagens e sede da fazenda.

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 realizadas 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. Em alguns talhões são plantadas árvores de uma única espécie, em outros existem o plantio de várias espécies, considerado como consórcio, ilustrado na Figura 11.

Figura 11 - Divisão da Fazenda por Talhão.



Fonte: (ONF BRASIL, 2012)

Tais dados são relevantes para a predição da quantidade de carbono em determinada área e/ou talhão específico ou, também, para a quantidade de carbono global da área reflorestada.

Um importante desafio em pesquisas florestais na Amazônia é o de encontrar melhores formas de reflorestar áreas que já foram degradadas com a utilização de um maior número de espécies nativas e identificar, entre as várias espécies tropicais comercialmente atrativas, quais são as melhores adaptadas a plantios em áreas abertas, a pleno sol (TONINI et al., 2008).

A recuperação de áreas degradadas é importante para atenuar o efeito estufa provocado pela emissão de gás carbônico e demais gases poluentes. Segundo Machado (1989) e Freitas (2004), essas florestas recuperadas proporcionam impactos benéficos para o meio ambiente. Por exemplo, o controle de erosão, melhorias da vazão hídrica, o estabelecimento de sistemas agroflorestais (SAFs), suporte a fauna terrestre e a diminuição da pressão sobre as florestas nativas.

Para a recuperação das áreas degradadas da Fazenda São Nicolau, foram plantadas mais de dois milhões de árvores, sendo 49 espécies nativas e duas consideradas exóticas, a Teca e o Jamelão, conforme ilustrado na Figura 12.

Figura 12 - Mudas de Espécies Arbóreas para o Reflorestamento.



Fonte: (ONF BRASIL, 2012)

4.2 DESCRIÇÃO DO EXPERIMENTO

O processo de desenvolvimento do sistema inteligente, capaz de realizar a predição da quantidade da emissão e do sequestro de carbono em áreas de reflorestamento, a curto, médio e longo prazo, utilizando a Rede Neural Artificial ART-Fuzzy-BP, basear-se-á no registro de dados fornecidos por um inventário florestal da área em estudo.

O banco de dados será composto por informações retiradas do inventário florestal de campo de alguns talhões, no período de 2003 a 2010, conforme a Tabela 3. Em resumo, a informação a ser usada para o treinamento e o diagnóstico da rede neural será composta por medidas advindas do sistema de aquisição de dados do inventário Florestal da Fazenda.


Tabela 3 - Síntese das Variáveis do Inventário Florestal.

Plantio	Talhao	Medicao	Arvore	Nome	Altura_(m)	Cap	Dap	Sobrevivencia	Estado
1999/2000	T01	10/09/2003	1	Caja	1,75	16	5,21	viva	Regular
1999/2000	T01	10/09/2003	2	Caja	1,20	17	6,43	viva	Ruim
1999/2000	T01	10/09/2003	3	Caja	2,20	22	11,21	viva	Bom
1999/2000	T01	10/09/2003	6	Caja	2,40	19,5	7,90	viva	Bom
1999/2000	T01	10/09/2003	7	Caja	3,50	18	5,73	viva	Regular
1999/2000	T01	10/09/2003	8	Caja	5,00	29,5	9,39	viva	Bom
1999/2000	T01	10/09/2003	10	Caja	4,50	21	6,68	viva	Bom
1999/2000	T01	10/09/2003	11	Caja	5,00	30	9,55	viva	Regular
1999/2000	T01	10/09/2003	12	Caja	2,00	17	6,55	viva	Ruim
1999/2000	T01	10/09/2003	13	Caja	4,00	18	5,73	viva	Ruim
1999/2000	T01	10/09/2003	14	Caja	1,95	17	6,79	viva	Bom
1999/2000	T01	10/09/2003	15	Caja	4,00	29	9,23	viva	Bom
1999/2000	T01	19/08/2004	1	Caja	1,50	21	8,68	viva	Regular
1999/2000	T01	19/08/2004	2	Caja	2,00	18	6,88	morta	Regular
1999/2000	T01	19/08/2004	3	Caja	3,50	17	7,13	morta	Bom
1999/2000	T01	19/08/2004	5	Caja	2,10	21	8,65	viva	Bom
1999/2000	T01	19/08/2004	8	Caja	1,80	27	9,56	viva	Bom

Fonte: Dados da pesquisa do autor

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) segundo Sanquetta (2002), ou seja, a circunferência do tronco medida a altura a 1,3 m do solo e o DAP (Diâmetro à Altura do Peito) conforme ilustrado na Figura 16.

Figura 13 – Representação do DAP na Árvore.




Fonte: Elaboração do autor.

Para o interesse desta pesquisa, serão analisadas as informações coletadas das unidades amostrais de alguns talhões identificando as espécies arbóreas ou arbustivas que foram plantadas numa área de 1.418,36 hectares, para recompor áreas que foram desmatadas. Em cada talhão, há possibilidade de existir vários arranjos com espécies de árvores diferentes, distribuídas e organizadas em espaçamentos variando entre 2 x 3 metros, 3 x 3 metros, 4 x 5 metros e 6 x 3 metros.

O primeiro talhão a ser analisado é o talhão 1, ilustrado na Figura 13, que se encontra 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 florestais plantadas, das quais, podem-se encontrar espécies de Cedro Rosa (*Cedrel sp.*), Caroba (*Jacaranda copaia*), Cajá (*Spondias mombin*), Parica (*Schizolobium amazonicum*) e da Teca (*Tectona grandis*). As mudas de árvores dessas espécies foram plantadas no ano de 1999 a 2000, respeitando o espaçamento, entre elas, de 4 por 5 metros.


Figura 14 - Dados do Talhão 1.



Fonte: (ONF BRASIL, 2012)

O talhão 2 possui uma área de 40,66 hectares e está situado as coordenadas geográficas 9°50'46.95"S de longitude e 58°15'49.61"O de latitude. Nesta mesma área da fazenda foram plantadas aproximadamente 18.855 espécies arbóreas com um espaçamento de 5 por 4 metros entre elas. Conforme é mostrado na Figura 14, podemos encontrar neste Talhão árvores da espécie da Caroba (*Jacaranda copaia*), Cajazeira (*Spondias mombin*), Parica (*Schizolobium amazonicum*), Teca (*Tectona grandis*), Cajueiro (*Anacardium giganteum*), Ipê Amarelo (*Tabebuia sp.*), Mogno (*Switenia macrophylla*) e da Caixeta (*Simaruba amara*).


Figura 15 - Dados do Talhão 2.



Fonte:(ONF BRASIL, 2012)

Na Figura 15 a ser analisada é apresentado o talhão 4, situado à 9° 50'35.87"S de latitude e 58°15'22.22"O de Longitude, abrangendo uma área de 16,32 hectares e com 7.139 espécies de árvores plantadas. As árvores foram plantadas com um espaçamento entre elas de 4 por 5 metros. Neste Talhão, encontram-se árvores das seguintes espécies: Cajueiro (*Anacardium giganteum*), Caxeta (*Simaruba amara*), Cajazeira (*Spondias mombin*), Mogno (*Switenia macrophylla*), Teca (*Tectona grandis*), Parica (*Schizolobium amazonicum*), Ipê Roxo (*Tabebuia sp.*), Parica (*Schizolobium amazonicum*), Pinho Cuiabano (*Parkia multijuga*) e a Cerejeira (*Torresea acreana*).

Figura 16 - Dados do Talhão 4.



Fonte: (ONF BRASIL, 2012)

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 (fósforo, pH, textura, quantidade de alumínio), distância entre o talhão e a mata ciliar, espaçamento entre as árvores e quantidade de espécies por talhão.

Através da análise das imagens que foram mencionadas anteriormente, pertencentes às árvores da base de dados do inventário do reflorestamento da fazenda, percebe-se que com o passar dos anos, as espécies vão crescendo e, conseqüentemente, vai aumentando a Altura e o DAP (Diâmetro à Altura do Peito) que é medido a 1,30 m do solo.

Visando tornar mais simples o sistema previsional, sem comprometer significativamente a qualidade das soluções, adotar-se-á um procedimento considerando-se somente uma árvore representativa do conjunto de árvores que, para fins de identificação desta pesquisa, será designada “Árvore Padrão (AP)”.

O cálculo da quantidade de carbono absorvido pelas árvores do reflorestamento da fazenda São Nicolau foi baseado na equação alométrica proposta por Higuchi et al. (1998). Essa equação, segundo o autor, estima a quantidade de peso fresco de uma árvore, onde deste valor, 40% é água e 60% é matéria ou peso seco. Em relação ao carbono, 48% deste peso seco é absorvido pela árvore, (VELASO; HIGUCHI, 2009), conforme as equações .

Peso fresco :

$$\ln \text{Peso_Fresco (KG)} = -2,694 + 2,038 \ln \text{DAP (cm)} + 0,902 \ln \text{Altura (m)} \quad (23)$$

Peso seco :

$$\text{Peso_Seco(kg)} = \text{Peso_Fresco} * 0,60 \quad (24)$$

Carbono absorvido pela árvore :

$$\text{Carbono_Absorvido (CA)} = \text{Peso_Seco} * 0,48 \quad (25)$$

As equações foram aplicadas individualmente, com o objetivo de calcular a quantidade de carbono absorvido por cada indivíduo.

O parâmetro CA_m da AP é definido da seguinte forma:

$$CA_m = \sum_{k=1}^N m_k CA_k \quad (26)$$

sendo:

CA : Carbono absorvido pela árvore;

CA_m : Carbono absorvido da árvore padrão;

CA_k : CA da k-ésima espécie.

$$CA_k = \frac{\sum CA_K}{\pi \cdot n_k} \quad (27)$$

$$m_k = \frac{n_k}{\sum_{j=1}^N n_j} \quad (28)$$

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:

Na Tabela 4, estão especificadas as grandezas invariantes no tempo.

Tabela 4 - Grandezas Invariantes no Tempo.

nt	ia	Nc	cs	Dt	ea	Qe
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

Fonte: Dados da pesquisa do autor

$$\mathbf{a} = [\mathbf{nt} \ \mathbf{ia} \ \mathbf{nc} \ \mathbf{cs} \ \mathbf{dt} \ \mathbf{ea} \ \mathbf{qe}] \quad (29)$$


$$\mathbf{b} = [\mathbf{d} \ \mathbf{CA}_m(t)] \quad (30)$$

t : tempo discreto;

$\mathbf{d} = [\mathbf{CA}_m(t-3) \ \mathbf{CA}_m(t-2) \ \mathbf{CA}_m(t-1)]$ (informações passadas do parâmetro $\mathbf{CA}_m$ em relação ao tempo corrente t);

A rede neural a ser usada (Figura 17) é composta por 2 módulos: (1) *ART-Fuzzy*; (2) Rede neural feedforward multicamadas com treinamento realizado usando-se o algoritmo *backpropagation* (Rede Neural BP).

Figura 17 - Sistema Neural ART-Fuzzy-BP.



Fonte: Elaboração do autor

Os vetores, usados nas redes neurais da família ART, são representados por linhas e não por colunas como habitualmente adotadas na literatura matemática. Esta notação segue a recomendação apresentada pelos criadores das redes neurais ART descendentes, (CARPENTER; GROSSBERG, 1991), tornando a compreensão, de tais redes neurais, mais inteligível. Os vetores e matrizes estão identificados no estilo **negrito**.

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 CA_m medidos em 3 tempos distintos: (t-3), (t-2) e (t-1).

O vetor **b** é constituído pelo vetor **d** acrescido do valor $CA_m(t)$ 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 abrigando, por exemplo, quatro instantes sequenciais (dados passados e o tempo corrente).

Outras estratégias, que visem melhorar o desempenho do sistema previsor, 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 (27)), formam o vetor **x** de entrada da rede neural BP.

Deste modo, o modelo de entrada-saída da rede neural BP é descrito por:

$$\mathbf{x} = [\mathbf{b} \ \psi] \text{ (entrada da rede neural BP)} \quad (31)$$

$$\mathbf{y} = [CA_m(t+1)] \text{ (saída da BP)} \quad (32)$$

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

4.3 APLICAÇÃO DA REDE NEURAL ART-FUZZY-BP

Para realizar a aplicação do sistema inteligente, “Rede Neural ART-*Fuzzy*-BP”, proposto para fazer a predição 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 nesta pesquisa têm como origem três diferentes talhões, já citados anteriormente, conforme especificados na Tabela 5.


Tabela 5 - Representação dos Talhões.

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

Fonte: Dados da pesquisa do autor

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, conforme a Figura 18.

Figura 18 - Processamento da Rede Neural ART-Fuzzy.



Fonte: Elaboração do autor

Na Tabela 6, estão especificados os parâmetros usados na fase de treinamento da rede ART-Fuzzy.

Tabela 6 - Parâmetros Fase de Treinamento.

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

Fonte: Dados da pesquisa do auto

Na Tabela 7 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, no ano de 2004.

Tabela 7 - Representação Binária das Grandezas Invariantes do Tempo.

Talhão								Data				Árvore				Nome Comum				F	Ph				T	A	Dist		
0	0	0	0	0	0	1	0	0	1	1	0	0	0	0	1	1	0	0	0	0	1	0	0	0	0	0	0	0	0
0	0	0	0	0	0	1	0	0	1	1	0	0	0	0	1	0	0	0	0	1	0	0	0	0	0	0	0	0	0
0	0	0	0	0	0	1	0	0	1	1	0	0	0	0	1	0	0	0	0	1	0	0	0	0	0	0	0	0	0
0	0	0	0	0	0	1	0	0	1	1	0	0	1	0	0	0	0	0	0	1	0	0	0	0	0	0	0	0	0
0	0	0	0	0	0	1	0	0	1	1	0	0	0	0	1	0	0	0	0	1	0	0	0	0	0	0	0	0	0
0	0	0	0	0	0	1	0	0	1	1	0	0	0	0	1	0	0	0	0	1	0	0	0	0	0	0	0	0	0
0	0	0	0	0	0	1	0	0	1	1	0	0	0	0	1	0	0	0	0	1	0	0	0	0	0	0	0	0	0
0	0	0	0	0	0	1	0	0	1	1	0	0	0	0	1	0	0	0	0	1	0	0	0	0	0	0	0	0	0
0	0	0	0	0	0	1	0	0	1	1	0	0	0	0	1	0	0	0	0	1	0	0	0	0	0	0	0	0	0
0	0	0	0	0	0	1	0	0	1	1	0	0	0	0	1	0	0	0	0	1	0	0	0	0	0	0	0	0	0
0	0	0	0	0	0	1	0	0	1	1	0	0	0	0	1	0	0	0	0	1	0	0	0	0	0	0	0	0	0
0	0	0	0	0	0	1	0	0	1	1	0	0	0	0	1	0	0	0	0	1	0	0	0	0	0	0	0	0	0
0	0	0	0	0	0	1	0	0	1	1	0	0	0	0	1	0	0	0	0	1	0	0	0	0	0	0	0	0	0
0	0	0	0	0	0	1	0	0	1	1	0	0	0	0	1	0	0	0	0	1	0	0	0	0	0	0	0	0	0
0	0	0	0	0	0	1	0	0	1	1	0	0	0	0	1	0	0	0	0	1	0	0	0	0	0	0	0	0	0
0	0	0	0	0	0	1	0	0	1	1	0	0	0	0	1	0	0	0	0	1	0	0	0	0	0	0	0	0	0
0	0	0	0	0	0	1	0	0	1	1	0	0	0	0	1	0	0	0	0	1	0	0	0	0	0	0	0	0	0
0	0	0	0	0	0	1	0	0	1	1	0	0	0	0	1	0	0	0	0	1	0	0	0	0	0	0	0	0	0
0	0	0	0	0	0	1	0	0	1	1	0	0	0	0	1	0	0	0	0	1	0	0	0	0	0	0	0	0	0
0	0	0	0	0	0	1	0	0	1	1	0	0	0	0	1	0	0	0	0	1	0	0	0	0	0	0	0	0	0
0	0	0	0	0	0	1	0	0	1	1	0	0	0	0	1	0	0	0	0	1	0	0	0	0	0	0	0	0	0
0	0	0	0	0	0	1	0	0	1	1	0	0	0	0	1	0	0	0	0	1	0	0	0	0	0	0	0	0	0
0	0	0	0	0	0	1	0	0	1	1	0	0	0	0	1	0	0	0	0	1	0	0	0	0	0	0	0	0	0

Fonte: Dados da pesquisa do autor

Na Tabela 8 são ilustrados os atributos variantes do tempo, originários da coluna 36, 37 e 38, que dão origem ao CA_m (Carbono absorvido pela árvore) que compõem os pares de vetores padrão de entrada **d** e, conseqüentemente, a constituição do vetor **b** e da saída **y**.

Tabela 8 - Representação das Grandezas Variantes do Tempo.

Alt	Cap	Dap
6,00	41,00	13,05
7,00	43,00	13,69
8,00	62,00	19,74
9,00	70,00	22,28
8,00	49,00	15,60
10,00	70,00	22,28
4,50	29,00	9,23
10,00	19,00	6,05
4,50	16,00	5,09
8,00	60,00	19,10
8,00	30,00	9,55
8,00	46,00	14,64
6,00	41,00	13,05
6,00	53,00	16,87
4,56	45,00	14,32
2,10	42,43	13,51

Fonte: Dados da pesquisa do autor

Após a subdivisão da base de dados, para cada talhão em relação às espécies que foram plantadas e ao ano do plantio, utilizando-se a Rede Neural ART-*Fuzzy*, módulo 1 do sistema, e considerando as grandezas invariantes temporais de cada árvore do talhão, encontra-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).


Utilizando-se o módulo 2 do sistema-Rede Neural BP, foi implementada a técnica de janelamento para encontrar o CA_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 CA_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 CA_m , uma previsão da absorção de carbono nos talhões analisados para um intervalo de tempo à frente. Esta fase do processo está mostrada na Figura 19.

Figura 19 - Processamento da Rede Neural ART-Fuzzy-



Fonte: Dados da pesquisa do autor

5 SEQUESTRO E ARMAZENAMENTO DE CARBONO POR ESPÉCIES FLORESTAIS

5.1 GASES DE EFEITO ESTUFA (GEE)

Os crescentes índices de emissão e concentração dos Gases de Efeito Estufa (GEE) que despejamos diariamente na atmosfera, através de ações como a industrialização, queima de combustíveis, os desflorestamentos e os incêndios, vêm dificultando consideravelmente a refletância da radiação solar, absorvida por esses gases, que tem a capacidade de reter o calor do sol na atmosfera, formando uma espécie de isolante em torno do planeta, impedindo que ele escape de volta para o espaço, fenômeno que vem agravando consideravelmente o aumento do efeito estufa, consequentemente, sendo considerado o aspecto preponderantemente responsável pelo aumento da média da temperatura global, ocasionando a mudança climática no planeta. Esse processo é conhecido pelo fenômeno do aquecimento global, que atualmente vem ocasionando possíveis desequilíbrios ambientais, com grandes impactos para os ecossistemas da Terra.

Entre os Gases de Efeito Estufa, os quais contribuem para o aumento do aquecimento global, o óxido nitroso, o metano (CH_4) produzido por processos naturais, o clorofluorcarbono (CFCs) muito utilizado em geladeiras, aerossóis, isolantes e equipamento de ar-condicionado, o dióxido de carbono (CO_2), descoberto pelo escocês Joseph Black, por volta de 1754, liberado através da queima de combustíveis fósseis (gás natural, petróleo e carvão) e através do desflorestamento. O desflorestamento, produzido por meio do corte e da queima das árvores, é considerado o mais agravante e que representa uma grande ameaça à sobrevivência do nosso planeta.

Alguns observatórios já se preocupam com essa questão do alto índice de desflorestamento em algumas regiões do nosso país, como é o caso do INPE, que desde 1988, vem monitorando e informando as Taxas Anuais do desflorestamento da Amazônia Legal, bem como o alto índice de queimadas em várias regiões do país. Essas taxas de desflorestamentos e queimadas são ilustradas no Figura 20 e nas Tabelas 9 e 10.


Essas informações foram coletadas e armazenadas através de classificação digital com imagens técnicas de georreferenciamento, pelo INPE - PRODES, produzindo um banco de dados geográfico multitemporal, com taxas anuais e estimativas para a data de 1 de agosto do ano de referência.

Tabela 9 - Taxas Anuais de Desflorestamento em km² .

Taxas Anuais Estados\Ano	2004	2005	2006	2007	2008	2009	2010	2011	2012	Var. 2011- 2012	Var. 2004- 2012
Acre	728	592	398	184	254	167	259	280	305	9%	-58%
Amazonas	1232	775	788	610	604	405	595	502	523	4%	-58%
Amapá	46	33	30	39	100	70	53	66	27	-59%	-41%
Maranhão	755	922	674	631	1271	828	712	396	269	-32%	-64%
Mato Grosso	11814	7145	4333	2678	3258	1049	871	1120	757	-32%	-94%
Pará	8870	5899	5659	5526	5607	4281	3770	3008	1741	-42%	-80%
Rondônia	3858	3244	2049	1611	1136	482	435	865	773	-11%	-80%
Roraima	311	133	231	309	574	121	256	141	124	-12%	-60%
Tocantins	158	271	124	63	107	61	49	40	52	30%	-67%
Amazônia Legal	27772	19014	14286	11651	12911	7464	7000	6418	4571	-29%	-84%

Fonte: (INPE, 2013)

Figura 20 - Desflorestamento - Amazônia Legal.



Fonte: (INPE, 2013)

Tabela 10 - Focos de Monitoramento de Queimadas Detectadas no Brasil-km².

Ano	Jan	Fev	Mar	Abr	Mai	Jun	Jul	Ago	Set	OuT	Nov	Dez	Total
2006	5140	3016	2676	1633	2573	5105	12669	55125	91971	38687	22559	13051	254205
2007	4568	2930	4425	1265	3470	8847	14839	73136	94526	32312	13095	4075	257488
2008	2125	1275	1239	1253	553	1287	4507	14528	39445	39264	12778	4995	123249
2009	2848	1140	1392	1078	2593	2962	6599	17559	29430	24202	23914	9494	123211
2010	2851	2386	2417	2200	3497	3642	16646	75305	85415	31489	16587	6856	249291
2011	1416	973	937	1152	1985	4578	8524	22477	50302	18691	12222	9830	133087
2012	2491	1436	2058	2194	3240	5891	13508	46289	62099	34221	13587	6824	193838
2013	2049	1591	1969	1374	2166	3898	5633	-	-	-	-	-	18680

Fonte: (INPE, 2013)

Atividades econômicas e industriais têm contribuído para aumentar o índice de emissão desses GEE no nosso planeta, principalmente da emissão do gás carbônico. Uma alternativa viável para atenuar o agravamento desse processo, e tentar reverter esse aumento da temperatura da Terra seria através do reflorestamento das áreas já desmatadas, com o plantio de inúmeras espécies de árvores, que na fase de crescimento, demandam de uma enorme quantidade de carbono para se desenvolverem e com isso, acabam ajudando a absorver o gás carbônico da atmosfera: sendo capaz de absorver e manter um estoque em média de 150 toneladas de carbono por hectare (dependendo do tipo de floresta).

Além de absorver e manter esse estoque de carbono em áreas de reflorestamento, ainda existe a possibilidade de regular as temperaturas máximas e mínimas, deixando embaixo dessas árvores, temperaturas mais amenas e, ainda, um índice de maior umidade relativa do ar em comparação com áreas desflorestadas, segundo Nunes e Rugnitz (2011).

5.2 O CARBONO E A FOTOSSÍNTESE NAS PLANTAS

Dos elementos químicos da tabela periódica, o carbono é considerado um dos mais importantes para estrutura dos seres vivos. O nosso corpo está formado por proteínas, carboidratos e lipídios, que são todos formados por carbono. Nos carboidratos, por exemplo, encontramos oxigênio, carbono e hidrogênio.


Ao respirarem, os animais retiram o oxigênio da atmosfera, devolvendo o gás carbônico, em compensação, enquanto as plantas vão crescendo, nos ajudam retirando o CO₂ da atmosfera e o utilizam na realização do processo da fotossíntese.

A fotossíntese é o processo em que as plantas, através das suas folhas verdes e alguns outros organismos, transformam energia luminosa em energia química, armazenadas nas moléculas de glicídios produzindo o seu próprio alimento. As plantas, por meio do processo da fotossíntese aproveitam a energia da luz solar para converter dióxido de carbono, água e minerais em compostos orgânicos e oxigênio gasoso (LINHARES; GEWANDSZNAJDER, 2000).

O processo da fotossíntese só ocorre na natureza com a absorção da energia do sol, através de moléculas de clorofilas podendo produzir até 6 ou mais moléculas de gás carbônico.

Os reagentes na fotossíntese são (CO₂) e (H₂O) e os produtos formados são gás oxigênio (O₂) e os glicídios.

A equação simplificada do processo da fotossíntese :




Essa reação fotólise da planta libera oxigênio se tornado, pode-se dizer, uma “purificadora” do ar atmosférico, segundo Treichel e Kots (1998).

A fotossíntese é realizada em duas etapas: a fase luminosa e a fase escura. Na fase luminosa ocorre a absorção da luz, quando ocorre a transformação da energia luminosa em energia de ATP.

As moléculas de ATP vão se espalhando e se dissolvendo gradativamente em várias partes das células, sendo usadas para o uso do metabolismo das plantas.

Ocorre então nesta etapa, a quebra das moléculas de água em hidrogênio e oxigênio, onde os átomos de hidrogênio são capturados pelo NADP (nicotinamida adenina dinucleotídeo fosfato) quando depois, a planta libera o oxigênio a atmosfera. Conforme está sendo ilustrado na Figura 21.

Figura 21 - Representação do Processo da Fotossíntese.



Fonte: Elaboração do autor

Na etapa conhecida por fotoquímica, a molécula de clorofila absorve energia luminosa, que é acumulada em elétrons que escapam da molécula, onde serão recolhidos por outras substâncias. Dependendo das substâncias que as transportam, os elétrons podem realizar dois caminhos: o da fotofosforilação cíclica e a fotofosforilação acíclica. Em ambos, os elétrons liberam energia que será utilizada para a síntese de ATP, através do processo conhecido por fosforilação. Processo pelo qual é adicionado ao ADP (adenina dinucleotídeo fosfato) um fosfato rico em energia. Como a energia do elétron depende diretamente da luz, pode-se afirmar que essas moléculas de ATP são produzidas por fotofosforilação (LINHARES; GEWANDSZNAJDER, 2000). Já a fixação do carbono depende indiretamente da luz, podendo ocorrer mesmo no escuro, caso existam a disponibilidade de ATP e NADP.

Através deste processo celular, a planta produz o seu próprio alimento constituído essencialmente por glicose via da energia da luz. Com isso, ocorre a eliminação do oxigênio à medida que a planta produz a glicose.

A glicose é utilizada pela planta na realização de suas funções metabólicas, ou seja, ela é o seu principal combustível. Sem ela, seria impossível manter suas funções vitais. O processo de formação da glicose se dá através de reação química, e esta, somente é possível como consequência da transformação da energia solar em energia química. Sem a fotossíntese, não existiria vida em nosso planeta, pois é através dela que se inicia toda a cadeia alimentar. Daí a grande importância das plantas, vegetais verdes e alguns outros organismos.

5.3 O CICLO DO CARBONO E SUA EVOLUÇÃO

O crescimento das plantas se dá através da fotossíntese, quando a energia solar e o carbono são capturados da atmosfera, produzindo oxigênio e hidratos de carbono (glicose). Através desse processo, as plantas são consideradas um dos principais sumidouros de carbono do planeta, mitigando os seus efeitos, pois fixam o carbono no solo através das suas raízes e dos fungos que as habitam, segundo um novo estudo publicado no periódico *Science*. O processo inverso ocorre quando as plantas respiram emitindo gás carbônico na atmosfera.


Alguns seres vivos, como plantas e algas são chamados de autótrofos e se alimentam por meio de fotossíntese conseguindo fabricar o seu próprio alimento, a partir de substâncias minerais ou inorgânicas, como o gás carbônico, a água e os sais minerais, sem depender de outros seres vivos para sobreviverem. Já os animais, os protozoários, os fungos e algumas bactérias são heterótrofos, sendo incapazes de produzir seu próprio alimento, buscando energia se alimentando de outros seres vivos. Os seres autótrofos são chamados de produtores por serem capaz de fabricar compostos orgânicos que servirão de alimento para os seres heterotróficos. Alguns animais heterótrofos são herbívoros por se alimentam somente de vegetais e são chamados de produtores.

Os animais carnívoros se alimentam dos herbívoros e são chamados de consumidores secundários. E em alguns casos, os consumidores secundários são alimentados por outros animais carnívoros, sendo considerados consumidores terciários.

Quando qualquer um desses organismos morrem, eles são alimentos por bactérias e fungos, também conhecidos por decompositores, os quais possuem a função de decompor a matéria orgânica dos seres mortos para obtenção de energia e nutrientes.

Na Figura 22 é ilustrada a cadeia do carbono iniciando nos seres produtores captados por outros organismos e finalizando pelos decompositores, devolvendo uma parte do carbono para o reinício do processo do ciclo.

Figura 22 - Ciclo do Carbono.



Fonte: Elaboração do autor

Os combustíveis fósseis formados pela decomposição de matéria orgânica, que são encontrados no fundo mar e em áreas profundas do solo.

A queima desses combustíveis fósseis gera um alto índice de emissão de gás carbônico e consequentemente, um aumento da temperatura terrestre ocasionado o aquecimento global.


Além disso, os combustíveis fósseis são responsáveis pelas emissões de enormes quantidades de gases poluentes, resultantes da queima destes combustíveis que são altamente prejudiciais à saúde dos seres humanos e animais em geral.

5.4 A EVOLUÇÃO DOS ÍNDICES DE GÁS CARBONO NA ATMOSFERA

A partir da Evolução Industrial, os seres humanos começaram a queimar gás natural, óleo e carvão para o transporte, energia e fabricação de máquinas. Desde então, aumentou a queima de combustíveis fósseis (gasolina, diesel e carvão), liberando uma enorme quantidade de dióxido de carbono que foram armazenados no solo.

Nas últimas décadas, verificou-se que está ocorrendo um processo de aumento da temperatura do globo terrestre, em função do índice de aumento das emissões desses gases poluentes, principalmente, os derivados da queima de combustíveis fósseis e pelo gás carbônico, ocasionando uma mudança no clima no planeta Terra. Alguns observatórios como o Administração Atmosférica e Oceânica Nacional dos Estados Unidos (NOAA), informam os índices de anomalias de temperatura que são medidos pela diferença dessas temperaturas e a média histórica global, conforme a Figura 23 e Tabela 11.

Figura 23 - Anomalias da Temperatura Global – 1981-2010.



Fonte: (NOAA, 2013)

O Painel Intergovernamental de Mudanças Climáticas (IPCC), criado em 1988 pela Organização das Nações Unidas (ONU), reúne cientistas de diversos países que trabalham com grupos interessados em identificar, divulgar e tentar minimizar os problemas relacionados ao impacto das mudanças climáticas e as possibilidades de mitigação dessas mudanças e, ainda, a limitação em fatores relacionados às emissões de gases de efeito estufa (GEE).

A Tabela 11 apresenta dados relacionados a essas mudanças climáticas que estão ocorrendo ao longo do tempo.

Tabela 11 - Registro de Anomalias do Clima.

Anos Mais Quentes	Anomalia (°C)
2001	0,55
2002	0,61
2003	0,62
2004	0,58
2005	0,65
2006	0,60
2007	0,59
2008	0,51
2009	0,59
2010	0,66
2011	0,53
2012	0,58
2013	0,62


Fonte: (NOAA, 2013)

As consequências desse aumento gradual da temperatura estão levando a aceleração na concentração de dióxido de carbono na atmosfera, adversos já sinalizados e percebidos nos dias atuais pelo aumento do nível das águas dos oceanos em ocorrência do derretimento das calotas polares, pelo surgimento de desertos ocasionando o desequilíbrio de vários ecossistemas com a extinção de muitas espécies vegetais e animais, pela incidência em grande escala de riscos de incêndios florestais, pelo o aumento das catástrofes climáticas com a evaporação das águas dos oceanos. Por último, pelo aparecimento de ondas de calor muito forte em quase todos os continentes, sendo considerado pela comunidade científica um dos primeiros efeitos visíveis do impacto do aquecimento global no nosso planeta.

Pesquisas confirmam alterações nos padrões de intensificação das chuvas em diversas regiões, aumentando a questão das secas em algumas regiões do globo de terrestre, afetando a biodiversidade do planeta, tendo em que algumas espécies não sobrevivem e nem resistem a climas mais secos e áridos. Em consequência disso, em elevadas temperaturas as plantas em sua fase de crescimento, tendem a absorverem menos gás carbônico da atmosfera.

Na Figura 24, é apresentado o alto índice de aumento de temperatura entre os anos de 2005 e 2015.

Figura 24 - Temperatura Global.




Fonte: (NOAA, 2013)

Ao longo dos últimos anos, a concentração do CO₂, medida em partes por milhão (ppm), tem aumentado consideravelmente. Antes da Revolução Industrial, no século 19, a concentração média de CO₂ era de cerca de 280 partes por milhão (ppm) e crescia a uma taxa de 0,7 ppm por ano. Porém, nos últimos anos, esta concentração vem aumentando, atingindo o índice de 2,1 ppm por ano.

Observatórios, responsáveis por informar os índices do dióxido de Carbono (CO₂), apontam que já alcançamos a marca de 400 ppm pela primeira vez desde o início das medições, em 1958. Segundo informações do IPCC (painel de mudanças climáticas da ONU), o ideal seria manter a concentração abaixo de 450 ppm para evitar que a temperatura chegasse ao limite, capaz de provocar sérios danos em todo o ecossistema. Desde 2000, a taxa de crescimento da concentração de CO₂ vem aumentando mais rapidamente do que nas décadas anteriores afirma Canadell et al. (2007).


As figuras 25 e 26, representam dados dos índices de aumento do dióxido de carbono na atmosfera, em partes por milhão (ppm), adaptadas segundo dados divulgados em 2013, pelo centro de monitoramento da Administração Atmosférica e Oceânica Nacional dos Estados Unidos (NOAA), entre os meses do ano e por algumas décadas, entre 2000 e 2013.

Figura 25 - Evolução Anual Global do CO₂.



Fonte: Adaptado de Noaa (2013)

Figura 26- Evolução Mensal Global do CO₂ por Décadas.



Fonte: Adaptado de Noaa (2013)

5.5 O SEQUESTRO DE CARBONO PELAS FLORESTAS

Com intensão de minimizar os impactos no meio ambiente e amenizar o agravamento do aquecimento global, pela elevação dos gases de efeito estufa (GEE), algumas medidas podem ser tomadas como modalidades dentro do Mecanismo de Desenvolvimento Limpo (MDL). Entre elas, medidas que envolvam projetos de preservação da floresta com práticas de reflorestamento e recuperação de áreas degradadas, contribuindo para absorção e armazenamento do dióxido de carbono (CO_2) presente na atmosfera.

As florestas constituem um estoque natural de carbono no processo de fixação desse carbono pelo acúmulo de biomassa em sua vegetação e, eventualmente, pela matéria orgânica que se acumula no solo durante o seu desenvolvimento. Essas florestas têm sido apontadas como alternativa para reduzir os gases do efeito estufa, que são os principais responsáveis pelas mudanças climáticas, como já vimos anteriormente.

Os ecossistemas florestais possuem uma biomassa maior do que os ecossistemas voltados para a agricultura. Por essa razão, a necessidade de se dar uma maior importância e atenção nas áreas já degradadas, como consequência de uma fracassada implantação de projetos que visam atividades agrícolas, com o desmatamento em regiões de matas virgens e, plantações de florestas econômicas e recuperação de ecossistemas naturais (CESARINI, 2002). A substituição de combustíveis fósseis pela biomassa das florestas vem a ser o meio mais efetivo para a redução nas emissões do gás carbônico na atmosfera, segundo Rochadelli (2001).

Baird (2002) destaca que o CO_2 pode ser absorvido por meio do crescimento de plantas selecionadas especialmente para esse fim e, ainda, que quanto mais rápido for esse crescimento, mais rápida será a remoção do dióxido de carbono da atmosfera.

O Painel Intergovernamental sobre a Mudança do Clima (IPCC) afirmou, em 2000, que as florestas sequestraram por ano, cerca de 1,6 gigatonelada de gás carbônico da atmosfera comparando, em 2004, com as emissões dos gases de efeito estufa que chegaram a 50 gigatoneladas.

As florestas são consideradas “sumidouros de carbono”, associadas ao armazenamento e absorção de carbono, com enorme relevância do ponto de vista econômico, social e ambiental. Tanto as árvores nativas, quanto as plantadas para reflorestamentos, ajudam a mitigar as mudanças climáticas retirando CO_2 da Atmosfera.

A comunidade científica, o governo e a sociedade já começam a se preocupar seriamente com as questões relacionadas ao aumento das emissões dos gases de estufa e respectivas consequências sobre as alterações globais do aquecimento no planeta. Existem vários projetos voltados para preservação das florestas, reflorestamento de áreas degradadas, combate a incêndios nas florestas e, também, de correção do solo em áreas castigadas por erosões, fruto das águas das chuvas que caem anualmente moldando a superfície do solo.

6 RESULTADOS E DISCURSÃO

O presente capítulo tem por finalidade apresentar e discutir, de forma detalhada, os resultados pertinentes à aplicação do sistema inteligente, “Rede Neural ART-Fuzzy-BP”, composto pelas redes neurais: ART-Fuzzy (CARPENTER; GROSBURG, 1991) e *Perceptron* Multicamadas, por meio do algoritmo de aprendizagem *backpropagation* (WERBOS, 1974), com significativo grau de confiabilidade no que diz respeito à metodologia adotada, proposto para realizar a predição do fluxo de carbono em áreas de reflorestamento.

6.1 CRITÉRIOS DE AVALIAÇÃO DA REDE NEURAL ART-FUZZY-BP


Nessa primeira aplicação, com base no inventário florestal da fazenda, foram extraídas informações do talhão 1, compreendidas entre os anos 2003 e 2010, com um arquivo de dados de 435 árvores, que sobreviveram ao plantio de mudas de aproximadamente 4.433 árvores, plantadas no início do reflorestamento.

Para aplicação dessa metodologia, foi utilizada uma base de dados com informações dessas árvores que restaram e, que compõem o conjunto dos pares de vetores de entrada-saída da rede neural, conforme a representação binária das grandezas invariantes do tempo, apresentada na Tabela 9.

Na implementação do janelamento, conforme ilustrado na Figura 27, adotou-se um período de tempo anual, de janeiro a dezembro, de 2003 a 2010, já conhecido o valor do CA_m , por informações aferidas de cada árvore pertence a análise dos talhões 1,2 e 4. Após o treinamento da rede, o diagnóstico foi realizado considerando 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. Com isso, foi realizada a previsão até 2016.

A autorização para o uso dos dados ambientais do inventário Florestal da Fazenda São Nicolau, como objeto de estudo da nossa pesquisa, titulada como “Previsão do Sequestro de Carbono em Área de Reflorestamento”, está alocada no anexo da tese.

Figura 27 - Representação do Deslocamento da Janela.



Fonte: Elaboração do autor.

Para a análise da precisão e do desempenho da previsão da rede neural que está sendo proposta, foi utilizado o Erro Máximo da Previsão e o Erro Percentual Absoluto Médio (MAPE), comparando os valores reais do CA_m com os previstos pela rede neural, conforme as equações (30) e (31), respectivamente.

$$\text{Erro máximo}(\%) = \max\left(\frac{|CA_m^{\text{Real}} - CA_m^{\text{Estimado}}|}{CA_m^{\text{Real}}}\right) \times 100 \quad (33)$$

$$\text{MAPE} = \frac{1}{N} \sum_{m=1}^N \frac{|CA_m^{\text{Real}}(m) - CA_m^{\text{Estimado}}(m)|}{CA_m^{\text{Real}}(m)} \times 100 \quad (34)$$

sendo que:

- CA_m^{Real} : valor do CA_m real (no campo);
- CA_m^{Estimado} : valor do CA_m estimado (na rede);
- N : número de amostras.

6.2 PARÂMETROS UTILIZADOS NA REDE NEURAL ART-FUZZY-BP

Os parâmetros da rede neural foram ajustados conforme a análise do comportamento dos resultados, apresentados na Tabela 12 e 13.

Tabela 12 - Especificações dos Parametros da Rede ART-Fuzzy.

Rede Neural ART-Fuzzy		
Taxa de treinamento	1,00	
Parâmetro de vigilância	Treinamento	Diagnóstico
	0,99	0,15
Parâmetro de escolha	0,10	0,10

Fonte: Elaboração do autor.

Tabela 13 - Especificações dos Parametros da Rede MLP.

Rede Neural MLP com algoritmo retropropagação (Backpropagation)	
Taxa de aprendizado	0,05
Fator de Momento	0,75
Número de neurônios por camadas	10-18-1
Lambda (λ)	1,0

Fonte: Elaboração do autor.

6.3 ANÁLISE DOS RESULTADOS DA REDE NEURAL ART-FUZZY-BP

Nesta seção, apresentam-se a análise dos resultados, gráficos e numéricos, da previsão do dióxido de carbono, obtidos pelo sistema inteligente proposto. Utilizando-se dos parâmetros das tabelas 12 e 13 na análise dos talhões, obtiveram-se os resultados do MAPE e do Erro Máximo, comparando os valores reais com os que foram previstos pela rede, dos talhões 1, 2 e 4 e das suas respectivas árvores, conforme ilustrados na Tabela 14, 15, 16 e 17.


Após o processo de janelamento e treinamento da rede neural neste primeiro talhão, a previsão do CAM foi realizada e os resultados da Rede Neural ART-Fuzzy-BP para a espécie arbórea da Teca, Parica e Cajá, sistema proposto neste experimento para previsão da absorção de carbono, mostrados nas Figuras 28, 29, 30 e 31.

Tabela 14 - Resultados Obtidos do Erro Máximo e do MAPE do Talhão 1.

	Espécies			
	Talhão 1	Teca	Parica	Cajá
Erro Máximo (%)	3,15	1,64	3,11	2,29
MAPE (%)	1,47	1,23	1,52	1,47


Fonte: Elaboração do autor.

Figura 28 - Representação Gráfica da Previsão do CA_m do Talhão 1.




Fonte: Elaboração do autor.

Figura 29 - Representação Gráfica da Previsão do CA_m da Teca no Talhão 1.




Fonte: Elaboração do autor.

Figura 30 - Representação Gráfica da Previsão do CA_m do Parica no Talhão 1.



Fonte: Elaboração do autor.

Figura 31 - Representação Gráfica da Previsão do CA_m do Cajá no Talhão 1.




Fonte: Elaboração do autor.

Os resultados do sistema predictor em relação ao MAPE e ao Erro Máximo do segundo talhão, o talhão de número 2, serão apresentados na Tabela 15 e a representação gráfica do talhão e das suas correspondentes árvores, nas Figuras 32, 33, 34 e 35.

Tabela 15 - Resultados obtidos do Erro Máximo e do MAPE do Talhão 2.


	Espécies			
	Talhão 2	Teca	Parica	Cajá
Erro Máximo (%)	2,29	3,10	3,10	2,95
MAPE (%)	1,15	1,18	1,43	1,14

Fonte: Elaboração do autor.

Figura 32 - Representação Gráfica da Previsão do CA_m do Talhão 2.


Fonte: Elaboração do autor.

Figura 33 - Representação Gráfica da Previsão do CA_m da Teca no Talhão 2.




Fonte: Elaboração do autor.

Figura 34 - Representação Gráfica da Previsão do CA_m do Parica no Talhão 2.



Fonte: Elaboração do autor.

Figura 35 - Representação Gráfica da previsão do CA_m do Cajá no Talhão 2.



Fonte: Elaboração do autor.


A Tabela 16 e as Figuras 31, 32, 33 e 34 expressam os resultados do MAPE e do Erro Máximo, obtidos com a rede neural na previsão do talhão 4, entre 2003 e 2016 e a representação gráfica da previsão de suas respectivas árvores.

Tabela 16 - Resultados obtidos do Erro Máximo e do MAPE.

	Espécies			
	Talhão 4	Teca	Parica	Cajá
Erro Máximo (%)	3,10	3,15	3,65	2,90
MAPE (%)	1,65	1,32	1,89	1,26


Fonte: Elaboração do autor.

Figura 36 - Representação Gráfica da previsão do CA_m no Talhão 4.




Fonte: Elaboração do autor.

Figura 37 - Representação Gráfica da Previsão do CA_m da Teca no Talhão 4.




Fonte: Elaboração do autor.

Figura 38 - Representação Gráfica da Previsão do CA_m da Parica no Talhão 4.



Fonte: Elaboração do autor.

Figura 39 - Representação Gráfica da previsão do CA_m do Cajá no Talhão 4.



Fonte: Elaboração do autor.

Tabela 17 - Comparação dos Resultados Obtidos entre os Talhões.

	MAPE (%)			Erro Máximo (%)		
	Talhão 1	Talhão 2	Talhão 4	Talhão 1	Talhão 2	Talhão 4
	1,47	1,15	1,65	3,15	2,29	3,10
Teca	1,23	1,18	1,32	1,64	3,10	3,15
Parica	1,52	1,43	1,89	3,11	3,10	3,65
Cajá	1,47	1,14	1,26	2,29	2,95	2,90

Fonte: Elaboração do autor.

É possível que o talhão 2 tenha apresentado melhores resultados em relação ao MAPE pelo fato de apresentar uma região bem maior que os demais talhões, e consequentemente, por possuir em sua área, um maior número de exemplares florestais nativos.

Foi possível constatar e identificar, através da análise dos resultados obtidos na Tabela 17, que o sistema mostrou-se adequado, pois os valores do MAPE foram inferiores a 2% e os do Erro Máximo em quase 4%, ou seja, com significativo grau de confiabilidade no que diz respeito à metodologia adotada, comparada com outros trabalhos da literatura.

7 CONCLUSÕES E SUGESTÕES PARA TRABALHOS FUTUROS

7.1 CONCLUSÕES

O presente trabalho propõe uma nova metodologia, através do uso de técnicas da inteligência artificial, baseado no estudo das redes neurais artificiais, no intuito de obter a predição do sequestro de carbono em áreas de reflorestamento, a curto, médio e longo prazo.

O método 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 executado via uso do algoritmo retropropagação *backpropagation*.

Através do uso da rede neural ART-Fuzzy obteve-se as classes auto-organizadas das grandezas invariantes no tempo, pertencentes a uma parte das características das árvores do inventário florestal que compõem a base de dados do reflorestamento na fazenda. A saída deste módulo, ou seja, a classe escolhida, é convertida em um vetor binário através de um código ativo, que compõem o vetor de entrada da rede acrescido do valor do $CA_m(t)$ que corresponde à realimentação da rede *backpropagation*, considerando-se um atraso igual a t (unidade de tempo). A saída da rede *backpropagation* corresponde à previsão em um intervalo de tempo à frente. Esta proposta consiste no deslocamento de uma janela temporal abrigando, por exemplo, quatro instantes sequenciais (dados passados e o tempo corrente).

Os resultados obtidos na comparação entre os valores reais e os estimados pela Rede Neural ART-Fuzzy-BP, na análise de cada talhão, são inferiores a 2% para o MAPE e não chegam a 4% para o erro máximo, atestando e validando o sistema inteligente proposto, no sentido de investigar a sua eficiência, provando que o sistema é viável, útil e bastante vantajoso, quando utilizado como técnicas de predição do sequestro de CO_2 em áreas reflorestadas, comparado com a literatura especializada.

É possível constatar através dos resultados obtidos, que a contribuição deste trabalho foi alcançada e que o sistema inteligente se mostrou útil no sentido de se fazer a predição do dióxido de carbono (CO_2) em áreas de reflorestamento, a curto, médio e em longo prazo, 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.

Dessa forma, é estabelecida uma contribuição para a comunidade científica da área de Redes Neurais, como também áreas correlatas que podem fazer uso das Redes Neurais, além de uma contribuição para o meio ambiente, visando à sustentabilidade ambiental.

7.2 SUGESTÕES PARA TRABALHOS FUTUROS

Para propostas futuras, recomenda-se:

- a) fazer um levantamento das espécies florestais que se encontram as margens de rios, comparando os resultados de previsão do CO₂ pelas redes neurais com árvores pertencentes a talhões próximos à mata ciliar;
- b) utilizar outras bases de dados para testar o sistema proposto na previsão do dióxido de carbono, oriunda de outras regiões do País;
- c) fazer a previsão do sequestro de carbono na floresta, com técnicas de redes neurais, considerando e comparando dados do solo, material orgânico e a biomassa;
- d) propor um novo método para comparar com a metodologia proposta nessa pesquisa;
- e) desenvolvimento de sistema semelhante ao proposto nesta pesquisa que contemple outras culturas e.g., cana de açúcar, soja, milho, etc.

REFERÊNCIAS

ALMEIDA, A. C.; BARROS, P. L. C; MONTEIRO, J. H. A; ROCHA, B. R. P. Estimation of aboveground forest biomass in amazonia with neural networks and remote sensing, *IEEE Latin America Transactions*, Piscataway, v. 7, n. 1, p. 27-32, 2009.

BAIRD, C. *Química ambiental*. 2. ed. Porto Alegre: Bookman, 2002.

BASHEER, I. A.; HAJMEER, M. Artificial neural networks: fundamentals, computing, design, and application. *Journal of Microbiological Methods*, Amsterdam, v. 43, p. 3–31, 2000.

BENDER, E. A. *Mathematical methods in artificial intelligence*. [S. l.]: IEEE Press, 1996.

CANADELL, J. G. et al. Contributions to accelerating atmospheric CO₂ growth from economic activity, carbon intensity, and efficiency of natural sinks. *Proceedings of the National Academy of Sciences*, Washington, v. 104, p. 1866-18870, 2007.

CARPENTER, G. A.; GROSSBERG, S. A massively parallel architecture for a self-organizing neural pattern recognition machine. *Computer Vision, Graphics and Image Processing*, Maryland Heights, v. 37, n. 1, p. 54-115, 1987. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S0734189X87800142>>. Acesso em: 5 nov. 2011.

CARPENTER, G. A.; GROSSBERG, S. A self-organizing neural network for supervised learning, recognition and prediction. *IEEE Communications Magazine*, New York, v. 30, n. 9, p. 38-49, 1992. Disponível em: <<http://cns.bu.edu/Profiles/Grossberg/CarGro1992IEEEComm.pdf>>. Acesso em: 5 nov. 2011.

CARPENTER, G. A.; GROSSBERG, S. ART 2: self-organization of pattern recognition codes for analog input pattern. *Applied Optics*, New York, v. 26, n. 23, p. 4919-4930, 1987.

CARPENTER, G. A.; GROSSBERG, S. ART 2-A: an adaptive resonance algorithm for rapid category learning and recognition. *Neural Networks*, New York, v. 4, n. 4, p. 493-504, 1991. Disponível em: <<http://www.sciencedirect.com/science/article/pii/0893608091900457>>. Acesso em: 5 nov. 2011.

CARPENTER, G. A.; GROSSBERG, S. ART 3: hierarchical search using chemical transmitters in self-organizing pattern recognition architectures. *Neural Networks*, New York, v. 3, n. 2, p. 129-152, 1990. Disponível em: <<http://www.sciencedirect.com/science/article/pii/089360809090085Y>>. Acesso em: 5 nov. 2011.

CARPENTER, G. A.; GROSSBERG, S.; MARKUZON, N.; REYNOLDS, J. H.; ROSEN, D. B. Fuzzy ARTMAP: a neural network architecture for incremental supervised learning of analog multidimensional maps. *IEEE Transactions on Neural Networks*, New York, v. 3, n. 5, p. 698-713, 1992.

CARPENTER, G. A.; GROSSBERG, S.; REYNOLDS, J. H. ARTMAP: supervised real-time learning classification of nonstationary data by a self-organizing neural network. *Neural Networks*, New York, v. 4, n. 5, p. 565-588, 1991.

CARPENTER, G. A.; GROSSBERG, S.; ROSEN, D.B. Fuzzy ART: fast stable learning and categorization of analog patterns by an adaptive resonance system. *Neural Networks*, New York, v. 4, n. 6, p. 759-771, 1991.

CESARINI, C. N. *Modelo de compensação de CO₂ para empresas poluidoras do ar: um estudo de caso no Vale do Itapocu, Região Norte de Santa Catarina*. 2002. 100 f. Dissertação (Mestrado em Engenharia de Produção) – Universidade Federal de Santa Catarina, Florianópolis, 2002.

COWAN, K. R.; HARMON, R.R. Carbon-sequestration technologies: a review of the current state of the art and market potential of managing carbon emissions. *PICMET Proceedings*, Istanbul, v. 3, p. 1166-1170, 2006.

DAUBECHIES, I. *Ten lectures on wavelets*. Philadelphia: Society for Industrial and Applied Mathematics, 1992.

FREITAS, L. C. Funções ambientais dos reflorestamentos. *Revista da madeira*, Curitiba, n.79, ano 13, p. 100, 2004.

HAYKIN, S. *Neural networks: a comprehensive foundation*. Upper Saddle River: Prentice-Hall, 1994.

HAYKIN, S. *Neural networks and learning machines*. 3. ed. New Jersey: Prentice-Hall, 2008.

HIGUCHI, N.; SANTOS, J. dos; RIBEIRO, R. J.; MINETTE, L.; BIOT, Y. Biomassa da parte aérea da vegetação da floresta tropical úmida de terra-firme da Amazônia brasileira. *Acta Amazônica*, Manaus, v. 28, n. 2, p. 153-166, 1998.

INSTITUTO NACIONAL DE PESQUISAS ESPACIAIS - INPE. *Figuras de desmatamento anual na amazônia legal por estados*. Brasília, DF, 2013. Disponível em : <http://www.inpe.br/noticias/noticia.php?Cod_Noticia=2786>. Acesso em: 20 maio 2013.

INSTITUTO NACIONAL DE PESQUISAS ESPACIAIS - INPE. *Comparação do total de focos ativos detectados por satélite*. Brasília, DF, 2013. Disponível em: <<http://www.inpe.br/queimadas/estatisticas.php>>. Acesso em: 25 maio 2013.

KOHONEN, T. The self-organizing map. *Proceedings of the IEEE*, New York, v. 78, n. 9, p. 1464-1480, 1990.

LEBLANC, A. Issues related to including forestry-based offsets in a GHG emissions trading system. *Environmental Science and Policy*, Exeter, v. 2, p. 199-206, 1999.

LINHARES, S.; GEWANDSZNAJDER, F. *Biologia hoje*. São Paulo: Árica, 2000. v. 1.

LOPES, M. L. M.; MINUSSI, C. R.; LOTUFO, A. D. P. Electric load forecasting using a Fuzzy ART&ARTMAP neural network. *Applied Soft Computing*, Amsterdam, v. 5, n. 2, p. 235-244, 2005.

MACHADO, C. C. *Exploração florestal*. Viçosa: Imprensa Universitária, 1989.

MAN YU, C. *Sequestro florestal de carbono no Brasil: dimensões políticas, socioeconômicas e ecológicas*. 2004. 293 f. Tese (Doutorado em Meio Ambiente e Desenvolvimento) - Universidade Federal do Paraná, Curitiba, 2004.

MARCHIORI, S. C.; SILVEIRA, M. D. C. G.; LOTUFO, A. D. P.; MINUSS, C. R. I.; LOPES, M. L. M. . Neural network based on adaptive resonance theory with continuous training for multi-configuration transient stability analysis of electric power systems. *Applied Soft Computing*, Amsterdam, v. 11, p. 706-715, 2011.

MEHDAWI, A. A.; BIN AHMAD, B. Classification of forest change by integration of remote sensing data with neural network techniques.. In: INTERNATIONAL CONFERENCE ON SYSTEM ENGINEERING AND TECHNOLOGY (ICSET), 2012, Bandung. *Proceedings...* Bandung: IEEE, 2012. p. 1-5, 11-12.

MICHAELOWA, A.; JOTZO, F. Transaction costs, institutional rigidities and the size of the clean development mechanism. *Energy Policy*, London, v. 33, n. 4, p. 511-523, 2005 .

MINUSSI, C. R.; LOTUFO, A. D. P. *Redes neurais: introdução e princípios*. Ilha Solteira: [s. n.], 2007. Apostila de Material Didático.

NATIONAL OCEANIC AND ATMOSPHERIC ADMINISTRATION - NOAA. *Figuras de monitoramento de anomalias do clima*. Asheville, 2013. Disponível em: <<http://www.ncdc.noaa.gov/monitoring-references/faq/anomalies.php>>. Acesso em: 12 abr. 2013.

NATIONAL OCEANIC AND ATMOSPHERIC ADMINISTRATION - NOAA. *Índice de temperatura global*. Asheville, 2013. Disponível em: <<http://www.ncdc.noaa.gov/national-temperature-index/>>. Acesso em: 21 maio 2013.

NUNES, P. C.; RÜGNITZ, M. T. *Semeando esperança, colhendo bens e serviços ambientais: resultados do projeto poço de carbono Juruena*. Juruena: Associação de Desenvolvimento Rural de Juruena (ADERJUR), 2011. Projeto Poço de Carbono.

ONF BRASIL. Projeto poço de carbono. Cotriguaçu, 1999. Disponível em: <http://www.reflorestamentoecarbono.com.br/novo/portal/view_onf.php>. Acesso em: 21 abr. 2012.

PROJETO RADAMBRASIL. *Folha S. C. 21 Juruena: geologia, geomorfologia, pedologia, vegetação e uso potencial da terra*. Rio de Janeiro, 1980.

PUENTE DE LA VEGA, M. L. B. *Fitomonitoração e modelagem de fotossíntese em Jatobá (*Hymenaea courbaril* L.) com redes neurais artificiais*. 2003. 248 f. Tese (Doutorado em Engenharia Elétrica) - Escola Politécnica, Universidade de São Paulo, São Paulo, 2003.

QI, G.; WANG, Q.; DAI, L.; WANG, X.; QI, L. Carbon sequestration in old-growth forest and plantations on changbai mountain in northeast China. In: INTERNATIONAL CONFERENCE ON BIOINFORMATICS AND BIOMEDICAL ENGINEERING – ICBBE, 4., 2010, Chengdu. *Proceedings...* Chengdu: IEEE Conferences,, 2010. p. 1-4.

ROCHADELLI, R. A estrutura de fixação dos átomos de carbono em reflorestamentos. 2001. 66 f. Tese (Doutorado em Ciências Florestais) – Universidade Federal do Paraná, Curitiba, 2001.

SAATCHI, S. S; HOUGHTON, R. A; ALVALA, R. C. S.; SOARES, J. V.; YO, Y. Distribution of aboveground live biomass in the amazon basin. *Global Change Biology*, Chichester, v. 13, p. 816–837, 2007.

SANQUETTA, C. R.; WATZLAWICK, L. F.; BALBINOT, R.; ZILIOOTTO, M. A. B.; GOMES, F. S. (Ed.). *As florestas e o carbono*. Curitiba: FUPEF, 2002.

SCHOENINGER, E. R. ; KOEHLER, H. S.; WATZLAWICK, L. F. ; OLIVEIRA FILHO, P. C. Uso de redes neurais artificiais como uma alternativa para mapeamento de biomassa e carbono orgânico no componente arbóreo de florestas naturais. *Ambiência*, Guarapuava, v. 4, p. 529-549, 2008.

SILVA, C. H. R. T. COP16: *Metas voluntárias e reforma do código florestal: o desmatamento no Brasil e a mitigação da mudança global do clima*. Brasília, DF: Centro de Estudos da Consultoria do Senado Federal, 2010. Disponível em: <<http://www.senado.gov.br/conleg/centroaltosestudios1.html>>. Acesso em: 4 nov. 2011.

SISTER, G. *Mercado de carbono e protocolo de Quioto: aspectos negociais e tributação*. Rio de Janeiro: Elsevier, 2007.

SOARES, C. P. B.; LEITE, H. G.; GORGENS, E. B. Equações para estimar o estoque do carbono no fuste de árvores individuais e em plantios comerciais de eucalipto. *Revista árvore*, Viçosa, v. 29, n. 5, p. 711-718, 2005.

TONINI, H. et al. Crescimento de espécies nativas da amazônia submetidas ao plantio no Estado de Roraima. *Ciência Florestal*, Santa Maria, v. 18, n. 2, p. 151-158, 2008.

TREICHEL JÚNIOR, P.; KOTZ, J. C. *Química e reações químicas*. Rio de Janeiro: LTC, 1998. v. 1.

VELASCO, G. D. N.; HIGUCHI, N. Estimativa de seqüestro de carbono em mata ciliar: projeto POMAR, São Paulo (SP). *Ambiência*, v. 5, n.1, p. 135-141, 2009.

WERBOS, P. J. *Beyond regression: new tools for prediction and analysis in the behavioral sciences*. 1974. 4 f. Thesis (PHD) - Harvard University, Harvard, 1974.

WIDROW, B.; LEHR, M. 30 years of adaptive neural networks: perceptron, madaline and backpropagation. *Proceedings of IEEE Neural Networks Congress*, New York, v. 78, n. 9, p. 1415-1442, 1990.

APÊNDICE – PUBLICAÇÕES DO AUTOR

Abaixo, apresentam-se os artigos completos, publicados em congressos, estritamente relacionados ao assunto abordado nesta tese:

NUNES, C. ; MARTINHO, V. R. C. ; MINUSSI, C. R. A new method for the prediction of carbon sequestration in reforested areas using a Fuzzy-ART-BP neural network. In: INTERNATIONAL CONFERENCE ON ARTIFICIAL INTELLIGENCE 2013 - ICAI'13, 2013, Las Vegas.. Proceedings... Las Vegas: ICA'13, 2013. v. 1. p. 825-831.

NUNES, C.; MARTINHO, V. R. C. ; MINUSSI, C. R. . Um novo método para a predição do sequestro de carbono em áreas de reflorestamento usando rede neural. In: CONGRESSO BRASILEIRO DE INTELIGÊNCIA COMPUTACIONAL (CBIC 2013), 11., 2013, Recife. Anais... Porto de Galinhas: CBIC, 2013. v. 1. p. 1-6.

NUNES, C.; MARTINHO, V. R. C. ; MINUSSI, C. R. . Predição do sequestro de carbono com espécies arbóreas nativas da amazônia por redes neurais artificiais. In: SIMPÓSIO BRASILEIRO DE AUTOMAÇÃO INTELIGENTE-SBAI2013, 11., 2013, Fortaleza. Anais... Fortaleza: SBAI, 2013 v. 1. p. 1-6.

ANEXO – AUTORIZAÇÃO DE USO DA BASE DE DADOS.



AUTORIZAÇÃO

ONF BRASIL GESTÃO FLORESTAL LTDA, inscrita no CNPJ sob nº 02.976.059/0001-45, estabelecida na Fazenda São Nicolau, Estrada Ariel, Zona Rural, município de Cotriguaçu/MT, CEP 78.330-000, Caixa Postal 63, representada pela Sra. **Cleide Regina de Arruda**, Diretora, Engenheira Florestal, M.Sc., registrada no CREA-MT nº 1207253243, autorizo a realização da pesquisa **"Predição do Sequestro do Carbono em Área Reflorestada utilizando Redes Neurais Artificiais"**, para obtenção do título de Doutor em Engenharia Elétrica, na Área de Conhecimento de Automação, no Programa de Pós-Graduação em Engenharia Elétrica da Faculdade de Engenharia Elétrica da Universidade Estadual Paulista "Júlio de Mesquita Filho" - UNESP - Campus Ilha Solteira, sob orientação do pesquisador **Profº. Dr. Carlos Roberto Minussi** e responsabilidade do pesquisador e doutorando **Clodoaldo Nunes**, no **Projeto de Reflorestamento para Sequestro de Carbono** sediado na Fazenda São Nicolau em Cotriguaçu, Mato Grosso, sendo este uma iniciativa da Peugeot e sob administração da ONF-Brasil Ltda, condicionada à prévia aprovação da mesma pelo **Comitê Científico do projeto "Poço de Carbono Peugeot/ONF"**, sob responsabilidade do pesquisador **Profº. Dr. Roberto de Moraes Lima Silveira**. Afirmando que fui devidamente esclarecida sobre a finalidade e objetivo da pesquisa, bem como sobre a utilização de dados exclusivamente para fins científicos e sua divulgação posterior.

Cuiabá, 22 de dezembro de 2012.


Cleide Regina de Arruda