

UNIVERSIDADE FEDERAL DO PARANÁ

LUCÍA VERÓNICA JARAMILLO TOLEDO

**AVALIAÇÃO MULTITEMPORAL DE ALTERAÇÃO DA COBERTURA
VEGETAL EQUATORIANA POR MEIO DE IMAGENS LANDSAT E REDES
NEURAS ARTIFICIAIS**

CURITIBA

2015

LUCÍA VERÓNICA JARAMILLO TOLEDO

**AVALIAÇÃO MULTITEMPORAL DE ALTERAÇÃO DA COBERTURA
VEGETAL EQUATORIANA POR MEIO DE IMAGENS LANDSAT E REDES
NEURAIS ARTIFICIAIS**

Dissertação apresentada ao Curso de Pós-Graduação em Ciências Geodésicas da Universidade Federal do Paraná, como requisito das exigências para a obtenção do título de Mestre em Ciências Geodésicas.

Orientador: Prof. Dr. Alzir Felipe Buffara Antunes

**CURITIBA
2015**

J37a

Jaramillo Toledo, Lucía Verónica

Avaliação multitemporal de alteração da cobertura vegetal equatorial por meio de imagens landsat e redes neurais artificiais / Lucía Verónica Jaramillo Toledo. – Curitiba, 2015.
124 f. : il. color. ; 30 cm.

Dissertação - Universidade Federal do Paraná, Setor de Ciências da Terra, Programa de Pós-Graduação em Ciências Geodésicas, 2015.

Orientador: Alzir Felipe Buffara Antunes.

1. Redes neurais artificiais. 2. Imagens de satélites. 3. Landsat. I. Universidade Federal do Paraná. II. Antunes, Alzir Felipe Buffara. III. Título.

CDD: 526.98

TERMO DE APROVAÇÃO

LUCÍA VERÓNICA JARAMILLO TOLEDO

"AVALIAÇÃO MULTITEMPORAL DE ALTERAÇÃO DA COBERTURA VEGETAL
EQUATORIANA POR MEIO DE IMAGENS LANDSAT E REDES NEURAIAS
ARTIFICIAIS"

Dissertação nº 288 aprovada como requisito parcial do grau de Mestre no Curso de Pós-Graduação em Ciências Geodésicas, Setor de Ciências da Terra da Universidade Federal do Paraná, pela seguinte banca examinadora:

Orientador:


Prof. Dr. Alzir Felipe Buffara Antunes
Departamento de Geomática, UFPR


Prof.ª Dr.ª Selma Regina Aranha Ribeiro
Universidade Estadual de Ponta Grossa, UEPG


Prof. Dr. Alvaro Muriel Lima Machado
Departamento de Geomática, UFPR


Prof. Dr. Hideo Araki
Departamento de Geomática, UFPR

Curitiba, 31 de julho de 2015.

DEDICATÓRIA

Para todas as mulheres da minha vida, especialmente Melania.

“A Joselo, quien ha compartido junto a mí años de alegría y tristeza, caminando por terrenos muchas veces inciertos hasta llegar a metas que se convierten en sueños realizados. Gracias por ser mi mejor amigo y mi mejor compañía en esta aventura”

AGRADECIMENTOS

Agradeço a todos que direta ou indiretamente ajudaram na realização deste trabalho:

Ao meu orientador, Prof. Dr. Alzir Felipe Buffara Antunes, pelo incentivo e ajuda proporcionados na realização deste trabalho;

Ao Prof. Dr. Jorge Antonio Silva Centeno, pelo apoio durante o tempo de permanência neste curso Pós-Graduação;

Ao Curso de Pós-Graduação em Ciências Geodésicas

Ao Governo do Equador que através da *Secretaría Nacional de Educación Superior, Ciencia, Tecnología e Innovación SENESCYT* forneceram a bolsa de estudos;

Aos colegas e amigos da Pós-Graduação em Ciências Geodésicas.

Un profundo y sincero agradecimiento a mi Madre (Melania) y Padre (Jorge) y a toda mi familia por la fuerza brindada y la compañía espiritual durante los años de ausencia. A mi amigos sudamericanos, aquella familia que escogí y me escogió bajo diversas circunstancias, ellos acompañan mi diario vivir.

RESUMO

A classificação e detecção de mudanças da cobertura vegetal em grandes áreas pode ser realizada mediante o uso das tecnologias associadas ao Sensoriamento Remoto. Imagens de satélite de média e alta resolução espacial e espectral contrastadas com informação coletada em campo, constituem ferramentas indispensáveis quando o objetivo de projetos e pesquisas é a discriminação entre distintos tipos de cobertura vegetal e suas variações temporais. As tarefas antes mencionadas de forma geral envolvem grandes investimentos em recursos humanos e econômicos, os resultados nem sempre são satisfatórios com a aplicação de algoritmos e técnicas orientadas à automatização do processo de classificação das distintas feições contidas na imagem, e em geral é requerida uma etapa de interpretação visual. As técnicas de Inteligência Artificial (IA), no caso específico das Redes Neurais Artificiais (RNAs) mostram ser um mecanismo adequado para realizar a classificação automática de imagens de satélite quando o objetivo é identificar mudanças na cobertura vegetal, sendo que o desempenho da técnica depende fundamentalmente do conjunto de dados de treinamento e da arquitetura da RNA. No presente trabalho, o método é testado em uma região da Amazônia equatoriana, o uso da técnica de RNAs para a detecção de alterações mediante imagens de satélite, apresentou melhores resultados do que aqueles obtidos com o método tradicional de máxima verossimilhança em termos de acurácia global e o coeficiente Kappa (superior a 0,8). Em geral, as alterações detectadas na cobertura vegetal natural estão associadas a fenômenos relacionadas com a expansão de áreas agrícolas e urbanas.

Palavras-chave: Redes Neurais Artificiais, Detecção de mudanças, Classificação, Segmentação.

ABSTRACT

The classification and change detection in vegetation cover over large areas can be accomplished using technologies associated with Remote Sensing. Satellite images of middle and high spatial and spectral resolution contrasted with information collected in the field are indispensable tools when the purpose of projects and research is discrimination between different types of vegetation and their temporal variations. The tasks mentioned above generally involve large investments in human and economic resources, the results are not always satisfactory with the application of algorithms and techniques aimed at the automation of the classification process of the different features contained in the image, and is usually required one-step visual interpretation. The Artificial Intelligence (AI) techniques, in the specific case of Artificial Neural Networks (ANN) prove to be an adequate mechanism for automating the satellite image classification when the goal is to identify changes in vegetation cover, and the technical performance depends the set of RNA training data. In this paper the method is tested in a region of the Ecuadorian Amazon, getting in terms of agreement, achieve a kappa index above 0,8.

Key-words: Artificial Neural Networks, Change Detection, Classification, Segmentation.

LISTA DE FIGURAS

FIGURA 1 - LOCALIZAÇÃO DA ÁREA DE ESTUDO	21
FIGURA 2 - CICLO DE VIDA DO INVENTÁRIO OPEN FORIS	27
FIGURA 3 - ESQUEMA DE UMA UNIDADE TÍPICA DE PROCESSOS.....	41
FIGURA 4 - ESQUEMA DE UMA REDE DE TRÊS CAMADAS INTERCONECTADAS	43
FIGURA 5 - MODELO DE NEURÔNIO ARTIFICIAL DE MCCULLOCH-PITTS47	
FIGURA 6 - ARQUITETURA DE UM PERCEPTRON COM N ENTRADAS E UMA SAÍDA	48
FIGURA 7 - FUNÇÃO SIGMOIDAL.....	51
FIGURA 8 - FUNÇÃO TANGENTE HIPERBÓLICA	52
FIGURA 9 - PROPAGAÇÃO DA INFORMAÇÃO EM UM PERCEPTRON MULTICAMADA.....	53
FIGURA 10 - CONFIGURAÇÃO DO PERCEPTRON PARA A SOLUÇÃO DA FUNÇÃO LÓGICA AND.....	54
FIGURA 11 - AJUSTAMENTO DE PONTOS MEDIANTE UMA FUNÇÃO M...	56
FIGURA 12 - MINIMIZAÇÃO DE UMA FUNÇÃO DE ERRO PELO MÉTODO DE NEWTON.....	57
FIGURA 13 - MINIMIZAÇÃO DA FUNÇÃO DE ERRO E	58
FIGURA 14 - MINIMIZAÇÃO DA FUNÇÃO DE ERRO E	60
FIGURA 15 - ESQUEMA GERAL DO PROCESSO A SEGUIR PARA DETECÇÃO ALTERAÇÕES NA COBERTURA VEGETAL	65
FIGURA 16 - SEGMENTAÇÃO MULTIDATA COM A BANDA DO VERMELHO ANO 1990	69
FIGURA 17 - SEGMENTAÇÃO MULTIDATA COM A BANDA DO INFRA- VERMELHO PROXIMO DO ANO 1990.....	69
FIGURA 18 - SEGMENTAÇÃO MULTIDATA COM A BANDA DO VERMELHO ANO 1999	69
FIGURA 19 - SEGMENTAÇÃO MULTIDATA COM A BANDA DO INFRA- VERMELHO PROXIMO DO ANO 1990.....	69
FIGURA 20 - SEGMENTAÇÃO MULTIDATA COM A BANDA DO VERMELHO ANO 2013.....	70

FIGURA 21 - SEGMENTAÇÃO MULTIDATA COM A BANDA DO INFRA-VERMELHO PROXIMO DO ANO 2013.....	70
FIGURA 22 - IMAGENS MOSTRANDO OS VALORES DAS MÉDIAS DOS NÍVEIS DIGITAIS DOS PIXELS CONTIDOS EM CADA SEGMENTO	71
FIGURA 23 - IMAGENS MOSTRANDO OS VALORES DAS MÉDIAS DOS NÍVEIS DIGITAIS DOS PIXELS CONTIDOS EM CADA SEGMENTO	71
FIGURA 24 - AMOSTRAS PARA A IMAGEM DO ANO 1990	74
FIGURA 25 - AMOSTRAS PARA A IMAGEM DO ANO 1999	75
FIGURA 26 - AMOSTRAS PARA A IMAGEM DO ANO 2013	76
FIGURA 27 - AMOSTRAS PARA TREINAMENTO DA RNA COM PIXELS PERÍODO 1	78
FIGURA 28 - AMOSTRAS PARA TREINAMENTO DA RNA COM PIXELS PERÍODO 2	78
FIGURA 29 - AMOSTRAS PARA TREINAMENTO DA RNA COM SEGMENTOS PERÍODO 1	79
FIGURA 30 - AMOSTRAS PARA TREINAMENTO DA RNA COM SEGMENTOS PERÍODO 2	80
FIGURA 31 - PARÂMETROS DE DESEMPENHO DA REDE	91
FIGURA 32 - MINIMIZAÇÃO DOS ERROS NOS CONJUNTOS DE TREINAMENTO, VALIDAÇÃO E TESTE DA RNA	91
FIGURA 33 - DESENHO DA REDE NEURAL ARTIFICIAL PARA O PRESENTE TRABALHO	92
FIGURA 34 - DETECÇÃO DE ALTERAÇÕES NO PERÍODO 1 UTILIZANDO RNA	100
FIGURA 35 - DETECÇÃO DE ALTERAÇÕES NO PERÍODO 2 UTILIZANDO RNA	101
FIGURA 36 - DETECÇÃO DE ALTERAÇÕES NO PERÍODO 1 UTILIZANDO MAXVER.....	102

LISTA DE TABELAS

TABELA 1 – COORDENADAS LIMITE DA ÁREA DE ESTUDO.....	21
TABELA 2 - INFORMAÇÃO DE PRECIPITAÇÃO NO EQUADOR	22
TABELA 3 - CLASSIFICAÇÃO DA COBERTURA VEGETAL.....	25
TABELA 4 – TÉCNICAS DE DETECÇÃO DE ALTERAÇÕES.....	31
TABELA 5 - CARACTERÍSTICAS TÉCNICAS DAS IMAGENS DE SATÉLITE UTILIZADAS NESTE TRABALHO.....	66
TABELA 6 - QUANTIDADE DE POLÍGONOS UTILIZADOS NAS AMOSTRAS DE TREINAMENTO PARA A IMAGEM DO ANO 1990	74
TABELA 7 - QUANTIDADE DE POLÍGONOS UTILIZADOS NAS AMOSTRAS DE TREINAMENTO PARA A IMAGEM DO ANO 1999	75
TABELA 8 - QUANTIDADE DE POLÍGONOS UTILIZADOS NAS AMOSTRAS DE TREINAMENTO PARA A IMAGEM DO ANO 2013.....	76
TABELA 9 - CLASSES PROPOSTAS PARA DETECÇÃO DE ALTERAÇÃO E NÃO ALTERAÇÃO	80
TABELA 10 - INTERVALOS DE NDVI PARA AS IMAGENS DOS ANOS UTILIZADOS NO ESTUDO	81
TABELA 11 - CLASSES ATRIBUÍDAS PARA O TREINAMENTO DA REDE ..	82
TABELA 12 - RESULTADO DA INTERPRETAÇÃO NOS DOMÍNIOS PROPOSTOS. COMPOSIÇÃO COLORIDA FALSA, BANDAS 4-3-2 (RGB)	85
TABELA 13 - MATRIZ DE CONFUSÃO PARA A CLASSIFICAÇÃO POR MÁXIMA VEROSSIMILHANÇA PARA A IMAGEM DO ANO 1990.....	87
TABELA 14 - ERROS DE OMISSÃO E INCLUSÃO PARA A IMAGEM DO ANO 1990 (MAXVER).....	87
TABELA 15 - MATRIZ DE CONFUSÃO PARA A CLASSIFICAÇÃO POR MÁXIMA VEROSSIMILHANÇA PARA A IMAGEM DO ANO 1999.....	87
TABELA 16 - ERROS DE OMISSÃO E INCLUSÃO PARA A IMAGEM DO ANO 1999 (MAXVER).....	88
TABELA 17 - MATRIZ DE CONFUSÃO PARA A CLASSIFICAÇÃO POR MÁXIMA VEROSSIMILHANÇA PARA A IMAGEM DO ANO 2013.....	88
TABELA 18 - ERROS DE OMISSÃO E INCLUSÃO PARA A IMAGEM DO ANO 2013 (MAXVER).....	88

TABELA 19 - ESTATÍSTICAS PARA OS DADOS DA RNA DO PERÍODO 1 COM DADOS DE SEGMENTAÇÃO E PIXELS	89
TABELA 20 - ESTATÍSTICAS PARA OS DADOS DA RNA DO PERÍODO 2 COM DADOS DE SEGMENTAÇÃO E PIXELS	90
TABELA 21 - ERRO QUADRÁTICO MÉDIO (RMS OBTIDO DURANTE AS ITERAÇÕES PARA OS COJUNTOS DE TREINAMENTO DA REDE.....	90
TABELA 22 - MATRIZ DE CONFUSÃO PARA A CLASSIFICAÇÃO POR RNA PARA A IMAGEM DO ANO 1990	93
TABELA 23 - ERROS DE OMISSÃO E COMISSÃO PARA A IMAGEM DO ANO 1990 (RNA.....	93
TABELA 24 - MATRIZ DE CONFUSÃO PARA A CLASSIFICAÇÃO POR RNA PARA A IMAGEM DO ANO 1999	93
TABELA 25 - ERROS DE OMISSÃO E COMISSÃO PARA A IMAGEM DO ANO 1999 (RNA).....	94
TABELA 26 - MATRIZ DE CONFUSÃO PARA A CLASSIFICAÇÃO POR RNA PARA A IMAGEM DO ANO 2013.....	94
TABELA 27 - ERROS DE OMISSÃO E COMISSÃO PARA A IMAGEM DO ANO 2013 (RNA).....	94
TABELA 28 - ACURÁCIA GLOBAL E ÍNDICE KAPPA	95
TABELA 29 - COMPARAÇÃO DAS CLASSIFICAÇÕES ENTRE OS MÉTODOS DE RNA E MAXVER.....	96
TABELA 30 - RESULTADOS DA DETECÇÃO DE ALTERAÇÕES UTILIZANDO O MÉTODO DE RNA.....	98
TABELA 31 - RESULTADOS DA DETECÇÃO DE ALTERAÇÕES UTILIZANDO O MÉTODO DE MAXVER	99

LISTA DE SIGLAS

ACCA	- <i>Automated Cloud Cover Assessment</i>
ADALINE	- <i>Adaptive Linear Neuron</i>
AVHRR	- <i>Advanced Very High Resolution Radiometer</i>
CIAT	- <i>Centro Internacional para la Agricultura Tropical</i>
EM	- <i>Expectation Maximization</i>
ETM	- <i>Enhanced Thematic Mapper</i>
FAO	- <i>Food and Agriculture Organization of the United Nations</i>
GDAL	- <i>Geospatial Data Abstraction Library</i>
GS	- <i>Gramm-Schmidt</i>
IGM	- <i>Instituto Geográfico Militar</i>
IPCC	- <i>Intergovernmental Panel on Climate Change</i>
INAMHI	- <i>Instituto Nacional de Meteorología e Hidrología</i>
IV	- <i>Índice de vegetação</i>
KT	- <i>Tasselled-cap</i>
LEDAPS	- <i>Landsat Ecosystem Disturbance Adaptive Processing System</i>
MAE	- <i>Ministério do Ambiente de Equador</i>
MAXVER	- <i>Máxima Verossimilhança</i>
SIGAGRO	- <i>Sistema de Informação Geográfica do Agro</i>
MODIS	- <i>Moderate Resolution Imaging Spectroradiometer</i>
NASA	- <i>National Aeronautics and Space Administration</i>
NDVI	- <i>Normalized Difference Vegetation Index</i>
NOAA	- <i>National Oceanic and Atmospheric Administration</i>
OLI	- <i>Operational Land Imager</i>
OS	- <i>Operative System</i>
PCA	- <i>Principal Component Analysis</i>
RAE	- <i>Región Amazónica Ecuatoriana</i>
RMS	- <i>Root Mean Square</i>
RNA	- <i>Rede Neural Artificial</i>
RNB	- <i>Rede Neural Biológica</i>
SIG	- <i>Sistema de Informação Geográfica</i>
SWIR	- <i>Shortwave infrared</i>

TIRS	- <i>Thermal Infrared Sensor</i>
TM	- <i>Thematic Mapper</i>
UIFRO	- União Internacional de Organizações de Pesquisas Florestais
USGS	- <i>United States Geological Survey</i>
UTM	- <i>Universal Transverse Mercator</i>
WGS84	- <i>World Geodetic System 84</i>
GLOVIS	- <i>Global Visualization Viewer</i>

SUMÁRIO

1 INTRODUÇÃO	18
1.1 OBJETIVOS	18
1.1.1 OBJETIVO GERAL	18
1.1.2 OBJETIVOS ESPECÍFICOS	19
1.2 JUSTIFICATIVA	19
1.3 PROBLEMA	20
1.4 HIPÓTESE	20
2 CARACTERÍSTICAS DA ÁREA DE ESTUDO	20
2.1 LOCALIZAÇÃO	20
2.2. CARACTERÍSTICAS FITOGEOGRÁFICAS DA REGIÃO	21
2.3 DESCRIÇÃO DAS CLASSES DE USO E COBERTURA DA TERRA	24
3 REVISÃO DE LITERATURA	26
3.1 PROJETO OPEN FORIS	26
3.1.1 COMPONENTES DO SISTEMA	28
3.2 DETECÇÃO DE ALTERAÇÕES	29
3.2.1 PRINCIPAIS TÉCNICAS DE DETECÇÃO DE ALTERAÇÕES	31
3.2.2 INTERPRETAÇÃO	32
3.2.3 SEGMENTAÇÃO	33
3.2.3.1 Crescimento de regiões por agregação de pixels	34
3.2.4 CLASSIFICAÇÃO	35
3.2.5. APLICAÇÕES DA SEGMENTAÇÃO E CLASSIFICAÇÃO DE IMAGENS NA ALTERAÇÃO DA COBERTURA VEGETAL	37
3.3 REDES NEURAIS ARTIFICIAIS	38
3.3.1 APLICAÇÕES DAS REDES NEURAIS ARTIFICIAIS	38
3.3.2 NEURÔNIO ARTIFICIAL	40
3.3.3 FUNCIONAMENTO DE UMA RNA	42

3.3.4	ESTRUTURA DA RNA.....	43
3.3.5	APRENDIZAGEM DA REDE NEURAL ARTIFICIAL	44
3.3.6	MODELOS NEURAIIS.....	47
3.3.6.1	Modelo neural de McCulloch-Pitts.....	47
3.3.6.2	<i>Perceptron</i>	47
3.3.6.3	ADALINE (<i>Adaptive Linear Neuron</i>).....	48
3.3.7	PROBLEMAS NÃO LINEARES.....	49
3.3.8	<i>PERCEPTRON</i> MULTICAMADA	50
3.3.9	FUNÇÕES DE TRANSFERÊNCIA.....	51
3.3.9.1	Função sigmoideal	51
3.3.9.2	Função tangente hiperbólica	52
3.3.10	Algoritmos de treinamento de uma RNA	53
3.3.10.1	Algoritmo de Treinamento do <i>Perceptron Multicamada</i>	53
3.3.10.2	Algoritmo de Retropropagação.....	54
3.3.11	Métodos para Minimizar Funções do Erro.....	56
3.3.11.1	Método de Newton	57
3.3.11.2	Método de Gauss-Newton.....	59
3.3.11.3	Método Levenberg Marquardt	63
4	MATERIAIS E MÉTODOS	65
4.1	AQUISIÇÃO E PRÉ-PROCESSAMENTO DAS IMAGENS LANDSAT 5 E LANDSAT 8	66
4.2	CORREÇÕES DAS IMAGENS.....	66
4.3	SELEÇÃO DAS BANDAS.....	67
4.4	SEGMENTAÇÃO DAS IMAGENS	68
4.4.1	MÉDIAS DOS VALORES DOS SEGMENTOS	70
4.5	INTERPRETAÇÃO DA IMAGEM	72
4.6	CLASSIFICAÇÃO DAS IMAGENS	72
4.6.1	CONFIABILIDADE DA CLASSIFICAÇÃO	76
4.7	AMOSTRAS - DADOS DE TREINAMENTO.....	77
4.8	APRENDIZAGEM DA REDE NEURAL ARTIFICIAL.....	83
4.8.1	TREINAMENTO DA RNA	83

5 RESULTADOS E DISCUSSÕES	85
5.1 RESULTADOS DA INTERPRETAÇÃO DAS IMAGENS.....	85
5.1.1 RESULTADOS DA CLASSIFICAÇÃO POR MÁXIMA VEROSSIMILHANÇA.....	86
5.1.2 RESULTADOS DO TREINAMENTO DA REDE NEURAL ARTIFICIAL	89
5.1.3 COMPARAÇÃO DE RESULTADOS.....	95
5.1.3.1 Classificação	95
5.1.3.2 Detecção de alterações.....	97
6 CONCLUSÕES E RECOMENDAÇÕES	104
6.1 CONCLUSÕES	104
6.2 RECOMENDAÇÕES	105
REFERENCIAS BIBLIOGRÁFICAS.....	106
ANEXOS	113

1 INTRODUÇÃO

As florestas cobrem cerca de 30% da superfície terrestre e são responsáveis diretos pelo funcionamento dos ecossistemas, desempenhando papel fundamental para a vida do planeta. O estudo e conhecimento das mudanças ao longo do tempo dos recursos florestais são essenciais para o bem-estar humano e saúde ambiental. A cobertura e uso da terra estão relacionados com a variação global do clima em pequena ou grande escala. As florestas são os principais transmissores e receptores de carbono no planeta, portanto as propriedades físicas da superfície da Terra dependem do seu estado.

O Equador é caracterizado por grande riqueza de flora e fauna, esta diversidade é atribuída, principalmente, à variedade de climas, tipos de solo e altitudes determinadas pela presença da Cordilheira dos Andes. No entanto, o desmatamento no país causado por vários fatores tais como expansão agrícola, atividades pecuárias, extração de madeira, processos industriais, etc., geram considerável degradação ambiental, sendo este um fenômeno comum em muitos países da América do Sul.

Atualmente, a consciência mundial de proteção ao meio ambiente tem levado aos governos em exercício, procurar soluções imediatas a fim de enfrentar e resolver este problema. Para isto, faz-se necessário dispor de informações detalhadas e atualizadas dos principais aspectos do território. Esta demanda de informação geográfica tem crescido significativamente nos últimos anos, acompanhada do crescente desenvolvimento tecnológico.

A disponibilidade de informação adequada e confiável sobre as mudanças da cobertura e uso do solo é fundamental para o planejamento territorial em busca do desenvolvimento sustentável do país.

1.1 OBJETIVOS

1.1.1 Objetivo Geral

Propor e avaliar uma metodologia para detecção de alteração na cobertura vegetal, utilizando a técnica de Redes Neurais Artificiais com uso de imagens de satélite multiespectrais de média resolução.

1.1.2 Objetivos específicos

- Avaliar a viabilidade do uso de uma Rede Neural Artificial (RNA) do tipo *Perceptron* Multicamada na detecção de alterações na cobertura vegetal de uma região da Amazônia Equatoriana ao nível de pixel e segmentos.
- Implementar um *script* desenvolvido em plataforma Matlab para o treinamento de uma Rede Neural Artificial do tipo *Perceptron* Multicamada que permita a detecção de alterações na cobertura vegetal ao nível de pixel e segmentos.
- Comparar os resultados obtidos do treinamento de uma RNA para detecção de alterações com aqueles advindos do método tradicional de máxima verossimilhança ao nível de pixel e segmentos.

1.2 JUSTIFICATIVA

Os dados estatísticos do desmatamento histórico registrado no Equador foram gerados por diferentes projetos de instituições governamentais e não governamentais; os métodos e processos usados para sua geração não estão devidamente documentados e os níveis de certeza associados aos dados não são especificados. Os aspectos antes mencionados determinam discrepâncias significativas nos valores de desmatamento gerados por diferentes projetos devido a não padronização de metodologia adequada e confiável para ser utilizada a nível nacional. Do exposto podemos concluir que a geração de informação atualizada sobre os processos de desmatamento que tenha como base uma metodologia apropriada é uma prioridade para o Equador.

Em 2008, o Ministério do Meio Ambiente de Equador iniciou o projeto "Mapa histórico de Desmatamento do Equador Continental" a fim de gerar dados históricos sobre as taxas reais de desmatamento no país, no entanto, a estratégia proposta para o desenvolvimento do projeto não dispõe de um método eficiente para detectar áreas de risco de desmatamento. As principais deficiências da metodologia usada são os longos tempos requeridos para gerar

a informação e as discrepâncias geradas quando os resultados obtidos são contrastados com produtos oriundos de outros projetos paralelos. Neste trabalho propõe-se a implementação de uma metodologia para detecção oportuna e confiável de alterações na cobertura vegetal, por meio de classificação de imagens livres mediante técnicas de inteligência artificial.

1.3 PROBLEMA

O processo de desmatamento no Equador não é adequadamente monitorado visto que não há sistematização da informação, bem como ausência de metodologia que facilite a detecção correta e oportuna de focos de desmatamento e de reflorestamento.

1.4 HIPÓTESE

A utilização de Redes Neurais Artificiais do tipo Perceptron Multicamada em imagens ou produtos de sensoriamento remoto constitui uma técnica eficiente para detectar alterações na cobertura vegetal mediante imagens de média resolução a custo razoável.

2 CARACTERÍSTICAS DA ÁREA DE ESTUDO

2.1 LOCALIZAÇÃO

O estudo é efetuado em uma área da Amazônia equatoriana. A região de estudo foi escolhida considerando-se o fator clima e a disponibilidade de imagens de satélite Landsat com menor cobertura de nuvens. A área selecionada para este estudo está localizada na Província de *Orellana*, com altitudes variando de 200 a 500 m. *Puerto Francisco de Orellana* e *Joya de los Sachas* são os principais núcleos urbanos na região. As coordenadas limite da área de estudo são (Tabela 1):

TABELA 1 – COORDENADAS LIMITE DA ÁREA DE ESTUDO

Norte	0° 16'	Sul	0° 35'
	14,9844''		12,7896''
Leste	76° 54'	Oeste	77° 6'
	50,9544''		10,2528''

FONTE: A Autora (2014)

Em função da superfície da área de trabalho (aproximadamente 734 Km²), e da sua compatibilidade com a resolução espacial das imagens Landsat, a escala do presente trabalho é fixada em 1:100 000.

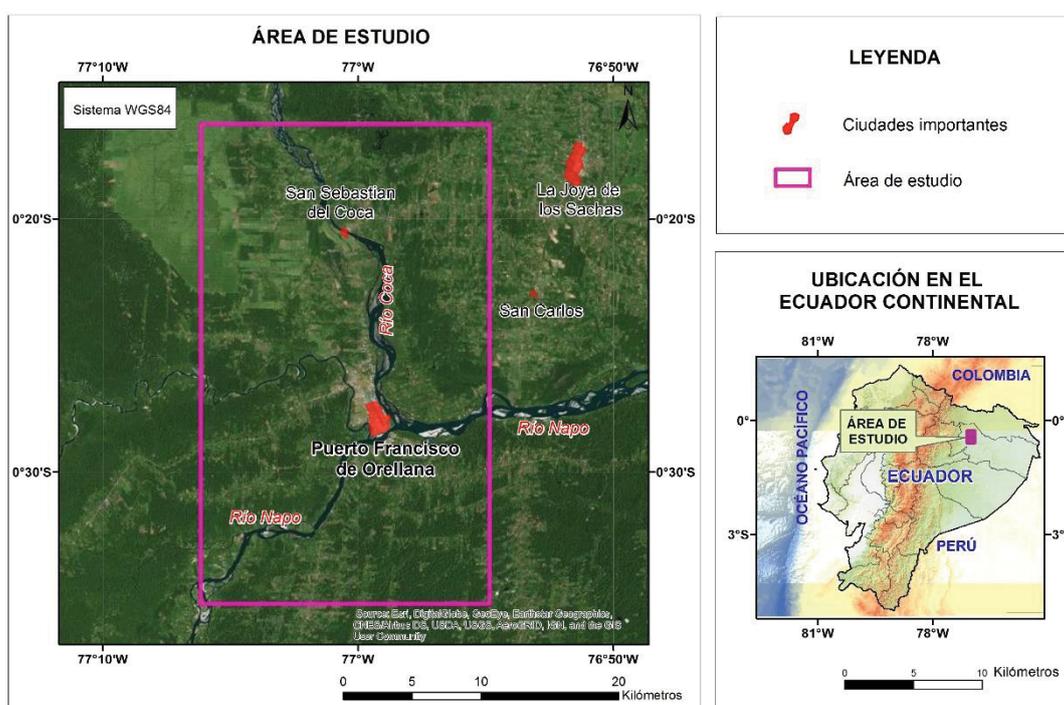


FIGURA 1 - LOCALIZAÇÃO DA ÁREA DE ESTUDO

FONTE: A Autora (2015)

2.2. CARACTERÍSTICAS FITOGEOGRÁFICAS DA REGIÃO

A Região Amazônica Equatoriana (RAE) corresponde aos territórios situados abaixo de 1300 metros no sopé oriental da Cordilheira dos Andes, incluindo todas as cordilheiras e as terras baixas do leste do limite definido. Esta região abrange aproximadamente 30% do território nacional, e está formada

pelas sub-regiões Norte e Central (Sierra 1999).

Devido à localização geográfica da RAE, sua topografia irregular e o fato de estar cruzada de norte ao sul pela Cordilheira dos Andes a qual encontra-se dividida em Cordilheira Oriental e Cordilheira Ocidental, o clima do Equador é diverso e não pode ser classificado como clima equatorial, pois possui variantes em função da altitude e da região (litoral, serra, oriental e insular). Em várias áreas do país a presença de nuvens é predominante, principalmente nos meses correspondentes ao período de chuvas (Tabela 2). A grande variedade de climas é uma característica dos Andes, onde a temperatura e a altitude mantêm alta correlação. A temperatura no Equador é influenciada, principalmente, pela proximidade com as montanhas e as correntes amazônicas e costeiras (Ecociencia, y otros 2004).

TABELA 2 - INFORMAÇÃO DE PRECIPITAÇÃO NO EQUADOR

Região	Província	Estação chuvosa	Estação Seca
Litoral	Esmeraldas	dezembro-maio	junho-novembro
	Santo Domingo de losTsáchilas	dezembro-maio	junho-novembro
	Manabí	dezembro-maio	junho-novembro
	Santa Elena	s/i*	s/i*
	Guayas	dezembro-maio	junho-novembro
	Los Ríos	dezembro-maio	junho-novembro
	El Oro	dezembro-maio	junho-novembro
Serra	Carchi	janeiro-maio setembro-novembro	junho-agosto
	Imbabura	janeiro-maio setembro-novembro	junho-agosto
	Pichincha	janeiro-maio setembro-novembro	junho-agosto
	Cotopaxi	janeiro-maio setembro-novembro	junho-agosto
	Tungurahua	janeiro-maio setembro-novembro	junho-agosto
	Bolívar	s/i*	s/i*
	Chimborazo	janeiro-maio setembro-novembro	junho-agosto
	Cañar	janeiro-maio setembro-novembro	junho-agosto
	Azuay	janeiro-maio setembro-novembro	junho-agosto
	Loja	janeiro-maio setembro-novembro	junho-agosto

Continua

TABELA 2 - INFORMAÇÃO DE PRECIPITAÇÃO NO EQUADOR

Conclusão

Região	Província	Estação chuvosa	Estação Seca
Oriental	Sucumbíos	s/i*	s/i*
	Orellana	janeiro-dezembro	não aplica
	Napo	s/i*	s/i*
	Pastaza	janeiro-dezembro	-
	Morona Santiago	s/i*	s/i*
	ZamoraChinchipe	s/i	s/i*
Insular	Galápagos	s/i*	s/i*

*s/i = sem informação

FONTE: Adaptado de Instituto Nacional de Meteorologia e Hidrologia – INAMHI <http://www.serviciometeorologico.gob.ec/biblioteca/>

Na região amazônica do Equador o clima varia de úmido para muito-úmido com temperatura média anual de 26 graus Celsius. O total de precipitação anual é de 3000 milímetros nas regiões próximas das zonas montanhosas, e situa-se no intervalo de 2500-3000 mm nas partes orientais; este fato determina a inexistência de formações secas (Ministerio del Ambiente del Ecuador 2012).

Ao contrário das outras regiões do Equador, na região amazônica houve maior mudança na cobertura vegetal até a segunda metade do século XX. Foi só no ano de 1947 que a primeira estrada foi construída nas planícies orientais, e antes disso o acesso era feito por pequenas trilhas na época de verão. No entanto, o rápido avanço da fronteira agrícola e as atividades relacionadas com exploração de petróleo produziram a transformação de grandes áreas, sendo que aproximadamente 12% da vegetação natural da região foi transformada em terras agrícolas e pastagens (Sierra 1999).

A região amazônica do Equador corresponde à província *florística* da Amazônia conhecida como *norte-oeste*, grande parte desta área constitui um dos maiores centros de biodiversidade das florestas tropicais definido como a região de *Napo* (Gentry 1988); (Valencia 1994). A região florística de *Napo* é um local de constantes invasões e recolonização das espécies e é coincidente com padrões de oscilação de temperatura e umidade. Estas flutuações climáticas provavelmente resultaram em condições favoráveis para processos de especiação. Esta diversidade resulta em mais de 4.800 espécies de plantas

vasculares, o equivalente a 32% da riqueza de espécies descritas para o Equador. As florestas de terra firme da província de *Sucumbíos* representam uma das maiores proporções de espécies por unidade de área em todo o mundo (Jorgensen, Ulloa y Maldonado 2006).

De acordo com o (Ministerio del Ambiente del Ecuador 2012), a região amazônica equatoriana representa 30% do território nacional, porém apenas 2% da bacia amazônica; esta inclui as planícies de inundação dos rios de origem andina e da área de sopé da Cordilheira Oriental. A presença de florestas de terra firme sobre pequenos montes, áreas de pântanos, florestas de palmeiras e lagoas de águas negras, são características do norte da região. A Amazônia central e sul estão dominadas por sedimentos de arenito e terraços aluviais associados com várzeas dos rios de água branca e preta, também com relevo homogêneo.

Regionalmente quatro unidades de vegetação principais são distinguidas: a floresta de terra firme (1); as florestas de várzea (2) nos rios de origem amazônica e andino, as florestas inundadas (3) localmente denominadas de *moretales* ou pântanos e as florestas de igapó (4). As florestas de terra firme, cobrem aproximadamente mais de 90% da Amazônia equatoriana, sendo distribuídas principalmente em solos argilosos que são pouco desenvolvidos e altamente lavados. O dossel da floresta atinge uma altura média de 25 a 30 m com espécies emergentes como *cateniformis Cedrelinga* (45-50 m de altura e 2-3 m DAP). O sub-bosque é normalmente aberto com arbustos e lianas principalmente. As epífitas são menos abundantes e diversificadas do que as suas homólogas dos Andes (Ministerio del Ambiente del Ecuador 2012).

2.3 DESCRIÇÃO DAS CLASSES DE USO E COBERTURA DA TERRA

De acordo com o uso e adaptação feita pelo *Ministerio del Ambiente del Ecuador* (2010) da lenda do Painel Intergovernamental sobre Mudanças Climáticas (IPCC, siglas em inglês) para o mapa do Projeto de Desmatamento Histórico, neste estudo foram estabelecidas as categorias para o Nível I da cobertura vegetal do Equador correspondente às classes de uso e cobertura da terra na região amazônica, segundo a tabela 3. O Nível I refere-se ao

componente estrutural e funcional das unidades de vegetação; também a sua fisionomia, sendo este o fator maiormente visível para ser detectado e avaliado. Este fator funcional é mensurável na escala global e separa a vegetação arbustiva e herbácea da vegetação arbórea (floresta) (Ministerio del Ambiente del Ecuador 2012).

TABELA 3 - CLASSIFICAÇÃO DA COBERTURA VEGETAL

IPCC (MAE)		
1 Floresta	<p>Áreas dominadas por elementos de árvores caracterizadas por ter um tronco lenhoso ramificado e formando uma coroa bem definida. O dossel mínimo é de 5 m de altura e pode atingir até os 35 metros de altura; a continuidade do dossel define uma cobertura de pelo menos 80% da superfície.</p>	
2 Áreas agropecuárias	<p>Áreas especialmente dedicadas à produção de alimentos, fibras e outras matérias-primas industriais, juntamente com as culturas e pastagens em rotação ou descanso.</p>	
3 Vegetação arbustiva e herbácea	<p>Cobertura constituída por uma comunidade vegetal dominada por elementos tipicamente arbustivos e herbáceos, desenvolvidos de forma natural em diferentes substratos.</p> <p>Vegetação arbustiva: áreas dominadas por espécies de plantas lenhosas geralmente ramificadas a partir da base do tronco, as quais neste caso não tem uma estrutura muito bem definida. A altura dos indivíduos é inferior a 5 metros e maior do que 1 m de altura.</p>	

Continua

TABELA 3 - CLASSIFICAÇÃO DA COBERTURA VEGETAL

Conclusão

IPCC (MAE)		
3 Vegetação arbustiva e herbácea	Vegetação herbácea: áreas compostas de espécies vegetais não lenhosas, sem ramificação e sem tronco definido cujas folhas podem ser anuais ou perenes.	
4 Corpos de água	Áreas que incluem: as águas interiores, como rios, lagos, lagoas, pântanos e remansos artificialmente como são os reservatórios.	
5 Áreas antrópicas	Áreas formadas por edifícios e espaços adjacentes à infraestrutura construída. Mais de 80% da área antrópica corresponde a edifícios e estradas. Áreas sem cobertura vegetal (solo exposto).	

FONTE: ADAPTADO DE *SISTEMA DE CLASIFICACIÓN DE LOS ECOSISTEMAS DEL ECUADOR CONTINENTAL* (Ministerio del Ambiente del Ecuador 2012)

3 REVISÃO DE LITERATURA

Neste capítulo encontra-se a descrição do embasamento teórico relacionado com o trabalho desenvolvido.

3.1 PROJETO OPEN FORIS

OPEN FORIS é um projeto criado em 2009 pela Organização para a Agricultura e Alimentação das Nações Unidas (FAO, sigla em inglês) a fim de

desenvolver, compartilhar e dar suporte a ferramentas e métodos de avaliação necessários para que países e instituições possam implementar Inventários Florestais Multipropósito (IFM). O projeto foi criado no marco do Programa da Floresta da FAO-Finlândia, em colaboração e apoio da FAO para o Monitoramento e Avaliação da Floresta Nacional. Entre seus objetivos específicos temos (OPEN-FORIS-FAO 2009):

- Enfrentar à crescente necessidade de informações precisas e oportunas sobre a situação dos recursos florestais e sua utilização.
- Dar solução as necessidades dos usuários mediante um conjunto de ferramentas de software livre altamente flexível e fácil de usar.
- Através da rede global de parceiros e especialistas, as ferramentas são elaboradas, testadas, implementadas e melhoradas para garantir seu funcionamento e proporcionar valor real aos beneficiários.

Estas ferramentas de software livre são usadas para ajudar aos países em tarefas de: compilação, produção e divulgação de informações fiáveis sobre o estado dos recursos florestais. Promove a autossuficiência, transparência e independência do provedor (OPEN-FORIS-FAO 2009).

As ferramentas Open Foris estão sendo construídas para suportar todo o Ciclo de Vida do Inventário Florestal, composto pelas 4 etapas apresentadas na Figura 2 (OPEN-FORIS-FAO 2009):



FIGURA 2 - CICLO DE VIDA DO INVENTÁRIO OPEN FORIS

FONTE: Adaptado de http://openforis.org/OFwiki/index.php/Main_Page (2014)

Entre as atividades maiormente desenvolvidas com o software *Open Foris* temos (OPEN-FORIS-FAO 2009):

- Inventários florestais
- Relatórios de mudança climática
- Estudos socioeconômicos
- Avaliação da biodiversidade
- Uso da terra, mudanças do uso da terra, medição florestal
- Monitoramento do desmatamento com sensoriamento remoto
- Detecção de desertificação

Um dos aspectos mais importantes que foram considerados no desenvolvimento das ferramentas *Open Foris* é que para reduzir as emissões de carbono por desmatamento, os países devem primeiro conhecer quanto de floresta realmente têm, quanto de carbono contém, e quanto dessa floresta está sendo perdida. Somente após ter esta informação, os países podem gerenciar suas florestas de forma sustentável (Pekkarinen 2014).

3.1.1 Componentes do Sistema

- *OPEN FORIS CALC*: É uma ferramenta utilizada para calcular os resultados dos Inventários Florestais Nacionais (IFNs). Permite que os usuários especialistas personalizem o *software* para calcular inventários específicos por região (OPEN-FORIS-FAO 2009).
- *OPEN FORIS COLLECT*: Administra a coleta de dados, permitindo variáveis definidas pelo usuário e a verificação dos dados. O sistema assegura a interoperabilidade e transparência dos dados mediante a aplicação de *Open Foris 'Inventario Metamodel Datos'*. Os dados são documentados e utilizam um formato padrão de metadados. A coleta está disponível de forma independente (sem conexão) e versões baseadas na web (*on-line*). A versão móvel está atualmente em desenvolvimento (OPEN-FORIS-FAO 2009).

- *OPEN FORIS GEOSPATIAL TOOLKIT*: É um conjunto de aplicações protótipo para o processamento de dados geoespaciais. As ferramentas compreendem programas *stand-alone* (independentes) e *scripts* (sequência de comandos) que têm sido testados em ambiente *Ubuntu Linux*. Eles podem ser utilizados com outros sistemas de *Linux*, *Mac OS* e *MS Windows (Cygwin)*. A maioria dos programas *stand-alone* utilizam bibliotecas *GDAL* (OPEN-FORIS-FAO 2009).

Open Foris está sendo utilizado com sucesso em mais de 10 países na África, Ásia e América do Sul, e foi apresentado no Congresso Mundial da União Internacional de Organizações de Pesquisas Florestais (UIFRO, siglas em inglês), em *Salt Lake City*, no Estados Unidos (OPEN-FORIS-FAO 2009).

3.2 DETECÇÃO DE ALTERAÇÕES

Os recursos naturais sempre foram o foco da atenção mundial para governos e instituições envolvidas na proteção do meio ambiente, devido à importância do seu uso e manutenção e o que eles representam para a humanidade. Metodologias baseadas em técnicas de sensoriamento remoto ajudam ao estudo das alterações que ocorrem nos recursos, geralmente associados à degradação ou recuperação. (FAO, 2005). Neste início de século, o interesse pelas questões ambientais tem aumentado à medida que os efeitos negativos sobre o ambiente vão-se tornando mais evidentes (Moreira 2007).

Segundo Singh (1986), a detecção de alterações é o processo usado para identificar variações no estado de um objeto ou um fenômeno mediante observação em épocas diferentes.

A detecção de alterações com imagens de satélite a partir de uma sequência multi-temporal é uma das principais aplicações do sensoriamento remoto. Este processo requer adequado tratamento das imagens em termos de correções, para que as alterações detectadas sejam atribuídas a alterações reais na paisagem (Ambrosio, González y Arévalo 2003).

Segundo Lu, *et al.* (2003), antes de realizar a detecção de alterações é necessário respeitar as seguintes condições importantes para que seja possível obter um resultado aceitável:

- Registro acurado das imagens de satélite multitemporais.
- Corrigir as imagens (radiometria e atmosfera), ou normalizar as imagens multitemporais.
- Quando possível, seleccionar as imagens com a mesma resolução espacial e a mesma época do ano.

A comparação das imagens multitemporais é usada principalmente para detectar alterações na cobertura do solo, para acompanhamento da evolução de áreas florestais, áreas de desastres naturais, expansão urbana, superfícies queimadas, etc. A maioria destas aplicações utilizam sensores, como *Landsat*, *NOAA-AVHRR*, *Spot*, etc., cobrindo grande área com resolução espacial média e baixa. Estas imagens, devido à facilidade de aquisição e baixo custo, constituem a melhor alternativa para pesquisadores, profissionais ou instituições que desejam analisar as características do terreno sem precisar ter alta resolução espacial, sendo este o caso do estudo da cobertura vegetal (Ambrosio, González y Arévalo 2003).

Segundo Lu, *et al.* (2003), nos últimos anos, têm sido estudadas várias técnicas teóricas e práticas para a detecção de alterações na cobertura da terra. Entre os aspectos destacados destes estudos tem-se:

- Área e tipo de mudança
- Distribuição espacial das alterações
- Evolução do uso da terra
- Avaliação da acurácia na detecção de alterações obtidas

Quando uma técnica de detecção de mudança é implementada é necessário seguir um processo específico, que pode ser definido da seguinte forma (Lu, y otros 2003):

1. Pré-processamento da imagem, dependendo do tipo de imagem utilizada e a abordagem do problema; podem ser feitas correções geométrica, radiométrica e atmosférica.
2. Escolha da técnica aplicada aos dados iniciais e produção de uma solução adequada para o problema proposto.
3. Avaliação da acurácia dos resultados.

3.2.1 Principais Técnicas de Detecção de Alterações

Segundo Lu, et al., (2003), entre as diversas técnicas de detecção de alterações em imagens de satélite temos (Tabela 4):

TABELA 4 – TÉCNICAS DE DETECÇÃO DE ALTERAÇÕES

Método	Técnica
Operações Algébricas	<ul style="list-style-type: none"> - Diferença de imagens - Regressão de imagens - Razão de imagens ou quociente - Diferença de índices de vegetação - Vetor de alterações - Subtração de fundo (<i>background subtraction</i>)
Métodos baseados em transformações	<ul style="list-style-type: none"> - Análises das componentes principais PCA - Transformação <i>Tasselled-cap KT</i> - Transformação <i>Gramm-Schmidt GS</i> - Chi-quadrado
Técnicas de classificação	<ul style="list-style-type: none"> - Comparação pós-classificação - Análises da combinação espectral de séries temporais - Detecção EM (<i>Expectation Maximization</i>) - Detecção de alterações com método híbrido - Redes Neurais Artificiais (RNAs)
Modelos avançados	<ul style="list-style-type: none"> - Modelo de refletividade de <i>Li-Strahler</i> - Modelo de mistura espectral - Método de parâmetros biofísicos
Sistemas de Informação Geográfica (SIG)	<ul style="list-style-type: none"> - Método integrado de SIG e sensoriamento remoto - Abordagem SIG
Análises visuais	<ul style="list-style-type: none"> - Interpretação visual

FONTE: ADAPTADO DE (Moya 2012)

Para o presente trabalho foi escolhida a técnica que combina a extração da informação espectral das imagens (segmentação e comparação, pós-classificação) com a análise utilizando RNAs.

A técnica de detecção de alterações baseado em RNAs usa

amostras puras e representativas para o treinamento; a quantidade e a qualidade dos dados são extremamente importantes para produzir resultados confiáveis. Uma vantagem deste método é a capacidade de fornecer uma matriz de mudanças, e ao mesmo tempo, reduzir o impacto das condições externas da atmosfera e ambiente das imagens multitemporais. No entanto, é necessário definir o conjunto de treinamento de forma correta e com número suficiente de dados para uma categorização adequada (Moya 2012).

Um adequado conjunto de dados de treinamento, coletado com um investimento econômico razoável e em tempos reduzidos, é necessário para que o método forneça os resultados esperados na detecção de alterações e otimizando os recursos.

A necessidade de imagens de satélite históricas é resolvida graças aos bancos de dados disponibilizados em sítios *web* especializados, como por exemplo aquele correspondente ao projeto *LANDSAT* da NASA.

3.2.2 Interpretação

Nos últimos anos têm havido algumas controvérsias sobre o melhor método para abordar o estudo da análise espacial em sensoriamento remoto. As imagens são adquiridas em forma numérica por conversão analógico-digital realizada a bordo do satélite, tal que o processamento digital é a opção de análise imediata. O método utilizado para interpretar a imagem, seja visual ou digital, deve ser analisado com a finalidade de conhecer qual o mais adequado para explorar o fluxo de dados que o sensoriamento remoto oferece. Vários aspectos que devem ser considerados na escolha do método de interpretação podem ser destacados, sendo os principais: recursos financeiros e recursos humanos disponíveis, rapidez e acurácia exigidas, continuidade das tarefas, e homogeneidade da superfície analisada (Chuvieco 1990).

Uma das principais restrições reside na diferença de percepção dos objetos pelo cérebro e a interpretação dos objetos pela máquina que em geral usa modelos simplificados. A principal vantagem da análise visual das imagens de satélite é a habilidade intelectual do cérebro humano que pode interpretar além da informação radiométrica fornecida pela imagem (Meneses y De Almeida

2012)

Já no caso da análise digital das imagens, esta fornece maior versatilidade, rapidez e acurácia dos resultados. O tratamento digital permite fazer operações complexas que resultam inacessíveis à análise visual (Chuvieco 1990).

A análise digital é feita utilizando recursos computacionais, e as informações são derivadas através de algoritmos. Estes métodos digitais tornam-se vantajosos principalmente quando a análise envolve bandas espectrais; nestes casos a capacidade do analista de visualizar as variações espectrais em todas as bandas é limitada (J. Centeno 2009).

Uma alternativa adicional para a interpretação de imagens de satélite é uma combinação dos dois métodos; o tratamento digital junto com a análise visual otimiza a qualidade dos resultados (Chuvieco 1990).

3.2.3 Segmentação

Quando usada a abordagem por regiões, o processo de segmentação representa o primeiro passo na preparação das imagens de satélite para futura classificação temática; este aspecto pode determinar o eventual sucesso ou fracasso da análise. O ato de segmentar uma imagem consiste em agrupar pixels com características similares em termos tonais e de textura, formando regiões homogêneas (Dlugosz, y otros 2005).

A segmentação de imagens divide a imagem nas suas partes constituintes para um nível de subdivisão em que as regiões ou objetos de interesse são isolados. Estas regiões contêm *pixels* ou objetos com características ou atributos semelhantes. Algoritmos de segmentação são baseados em duas propriedades básicas: descontinuidade ou similaridade entre os níveis digitais de pixels vizinhos (González & Woods, 2002).

A segmentação de imagens é feita com base no conteúdo da mesma. Segundo Ortiz E. (2009), o nível de informação utilizado para a segmentação é importante e pode ser definido segundo dois critérios fundamentais:

1. *Bottom-up*, que tenta deduzir entidades significativas (idealmente objetos) apenas a partir da análise das características visuais da imagem como:

homogeneidade da cor, textura e características geométricas. Esta abordagem também é referida aos métodos que ligam de forma iterativa aos pixels.

2. *Top-Down*, que segmenta a imagem em objetos cujas características são mais consistentes com os modelos utilizados, sendo que as características geométricas da imagem também são utilizadas.

O método que avalia a descontinuidade considera a mudança abrupta dos valores de cinza e o método por similaridade fundamenta-se na agregação de pixels em função da sua semelhança com os pixels vizinhos (Gonzalez y Woods 2002).

De acordo com Antunes (2003), não existe um modelo formal para a segmentação, sendo esse processo essencialmente empírico e, em geral, ajustável aos diferentes tipos de imagens, com limiares definidos conforme a complexidade dos alvos investigados. Por tanto o resultado da classificação de imagens baseada em objetos depende da qualidade da segmentação.

Segundo Araki, (2005), a classificação em regiões parte do conceito de obter um conjunto de regiões uniformes a partir da imagem original, as mesmas que serão o alvo do processo de classificação.

3.2.3.1 Crescimento de regiões por agregação de pixels

Neste processo pixels ou sub-regiões são agrupados em regiões maiores. O princípio da técnica baseia-se em começar com um conjunto de pontos geradores, a partir dos quais as regiões crescem ao ser agregados os pontos mais próximos com propriedades semelhantes (nível de cinza, textura, cor, etc.). A determinação dos pixels semente é um aspecto crítico no processo, uma vez que influenciam fortemente o progresso da segmentação. A definição das regras de crescimento depende do tipo de imagem a ser processada. Uma vez que as propriedades de semelhança são definidas, avalia-se o conjunto de pixels de tal forma que se estes satisfazem as regras de agrupamento, e formarão parte da região analisada ou objeto (Gonzalez y Woods 2002).

Sendo R a representação da imagem completa, a segmentação por região pode ser interpretada como o processo de subdivisão de R em n sub-regiões, $R_1, R_2, R_3, \dots, R_n$, tal que:

1. $\bigcup_{i=1}^n R_i = R$
2. R_i é a região conexa, onde $i = 1, 2, \dots, n$
3. As regiões devem ser disjuntas, tal que: $R_i \cap R_j = \emptyset$, para todo i e j , $i \neq j$
4. $P(R_i) = \text{verdadeiro}$ para $i = 1, 2, \dots, n$
5. $P(R_i \cup R_j) = \text{falso}$ para $i \neq j$

A condição (1) sugere que a segmentação deve ser completa. A condição (2) requer que os pixels de uma mesma região sejam conexos.

É difícil estabelecer um limite para a expansão da região, pode-se levar em conta o número de pixels em uma região, seu histograma, etc. (Gonzalez y Woods 2002).

3.2.4 Classificação

O processo denominado de classificação digital da imagem é aquele que parte da hipótese de que os pixels que cobrem um mesmo alvo devem ter características espectrais similares. Mediante o uso de algoritmos computacionais divide-se esses pixels em grupos, segundo suas leituras em cada banda espectral (J. Centeno 2009).

Tradicionalmente a classificação por pixel é frequentemente utilizada para a análise de imagens orbitais; esta classificação considera a radiância refletida de cada pixel para atribuí-lo a uma classe particular (Blaschke y Strobl 2001). O uso desta metodologia pode classificar pixels como pertencendo a uma classe dentro de um grupo maior de pixels classificados numa classe diferente. Isto acontece porque os critérios de atribuição não consideram a vizinhança entre pixels. Para corrigir este problema, aplica-se filtros pós-classificação, eles vão dar uniformidade às classes, atribuindo os pixels isolados ou pouco representativos às classes vizinhas majoritariamente representadas (Chuvieco 1990).

Na classificação supervisionada, o usuário define as classes e apresenta amostras ao computador, a partir das quais pode-se calcular parâmetros

estatísticos para descrever cada classe (J. Centeno 2009). A classificação por Máxima Verossimilhança é um método de classificação supervisionada pixel a pixel, que trata os dados estatisticamente. Utiliza a média e covariância das amostras de treinamento, e assume que as classes possuem distribuição normal. A partir destes parâmetros pode ser calculada a probabilidade estatística de que um pixel desconhecido pertença a uma ou outra classe (Crosta 2002). A probabilidade de se encontrar um pixel com um vetor de estado x numa imagem pode ser então representada por $p(x)$. Como na imagem existe um limitado número de vetores x , o processo de classificação consiste em definir a classe mais provável para estes pixels. Ou seja, dado o valor de x definir a classe mais provável w_j , dentre um conjunto finito de classes possíveis: $w = w_1, w_2, \dots, w_n$. Isto pode ser expresso pela probabilidade condicional $p(w_j|x)$. O conceito de probabilidade condicional também pode ser usado para descrever a frequência dos pixels numa classe. Ou seja, dada uma classe, pode-se descrever a probabilidade de se encontrar um determinado pixel neste grupo ($p(x|w_j)$). A partir dos valores destas probabilidades conjuntas, torna-se viável calcular a probabilidade de um pixel ocorrer na imagem, pois este valor está associado à probabilidade do pixel ocorrer em qualquer uma das classes (J. Centeno 2009).

O Teorema de Bayes (Richards y Jia 1999) é uma expressão de probabilidade condicional e serve para estimar a probabilidade de uma classe ocorrer, dado que o pixel com leituras descritas pelo vetor de estado $p(x)$ é observado na imagem.

$$p(w_j|x) = \frac{p(x|w_j)*p(w_j)}{p(x)} \quad 3.1$$

Dos três termos na relação, o primeiro corresponde à função densidade de probabilidade dos pixels na classe $p(x|w_j)$. Este termo descreve a frequência relativa dos pixels em uma determinada classe. O segundo termo $p(w_j)$ descreve a probabilidade a priori das classes, ou seja, a probabilidade de cada classe ocorrer na imagem. O terceiro termo descreve a probabilidade do pixel ocorrer na imagem. A decisão a ser tomada obedece à regra: o pixel x pertence à classe (w_j) se a probabilidade que associa este pixel à classe (w_j) é maior que a probabilidade que associa o pixel a qualquer outra classe, o que pode ser escrito

da seguinte maneira (J. Centeno 2009):

$$x \in w_j \text{ se } p(w_j|x) > p(w_k|x) \quad \forall j \neq k \quad 3.2$$

3.2.5. Aplicações da segmentação e classificação de imagens na alteração da cobertura vegetal

Nesta seção são apresentadas algumas aplicações da segmentação e classificação de imagens de satélite em trabalhos orientados à detecção de alterações da cobertura vegetal.

Segundo Barbosa do Nascimento, Parise, e Pinheiro (2012), na avaliação de técnicas de classificação de imagens do tipo SAR (*Synthetic Aperture Radar*), os melhores resultados obtidos para classificação de imagens, baseando a análise de resultados no cálculo de coeficientes *Kappa*, foram os obtidos com a aplicação previa da técnica de segmentação de imagens.

De acordo com o trabalho de Antunes (2003), a classificação baseada ao nível de pixel não permite fazer o amplo uso das potencialidades espectral e espacial das imagens. A interpretação da imagem segmentada é tão importante quanto a interpretação multiespectral, uma vez que as propriedades espaciais, tais como forma, tamanho e orientação, são bem evidentes. Os objetos da imagem, quando associados aos pixels que lhe deram origem, conduzem a uma percepção menos abstrata da cena.

O trabalho realizado pelo projeto OPEN-FORIS-FAO (2009) para detecção de alterações na vegetação, faz uma segmentação multi-data usando imagens Landsat e o Índice de Vegetação por Diferença Normalizada (NDVI); parte deste método foi aplicado na metodologia de "Linha de Base do Desmatamento" para Equador (Ministerio del Ambiente del Ecuador 2010).

No projeto desenvolvido pelo INPE, "Mapeando Alterações da Cobertura Vegetal pelo Método Panamazônia: Caso Exemplo do Município de SINOP-MT", as imagens que contém os melhores atributos referentes ao desflorestamento e seus descendentes, tipo rebrotas e culturas, são segmentadas em oito classes segundo limiares estabelecidos. Esta segmentação passa ser o principal insumo do processo de detecção de alterações na cobertura vegetal (INPE 2010).

Anteriormente, os trabalhos relacionados com classificação ou detecção de alterações com imagens de satélite utilizavam a informação ao nível do pixel; porém, graças a pesquisas realizadas por vários autores, nota-se que existe uma melhora significativa na qualidade dos resultados obtidos quando usadas imagens segmentadas como insumo da classificação ou detecção de mudanças. Neste trabalho, com o objetivo de fazer uma análise comparativa, além da segmentação por crescimento das regiões por agregação de pixels, é usada a análise ao nível do pixel.

3.3 REDES NEURAIIS ARTIFICIAIS

Desde os tempos antigos, um dos grandes enigmas do ser humano tem sido o estudo de seu próprio cérebro; suas características o torna muito diferente de outros cérebros animais. Inúmeros filósofos e cientistas têm tentado interpretar o seu funcionamento, porém a capacidade do cérebro humano para resolver problemas do cotidiano continua a ser uma tarefa completamente indecifrável, devido à complexidade da inteligência que nos caracteriza como espécie (Isasi y Galván 2004).

As RNAs como parte integrante das técnicas de inteligência artificial, têm como objetivo reproduzir a capacidade de aprendizado do cérebro humano utilizando máquinas, simulando tanto quanto possível a estrutura e funcionamento das Redes Neurais Biológicas (Isasi y Galván 2004).

3.3.1 Aplicações das Redes Neurais Artificiais

As RNAs oferecem um paradigma interessante para a construção e análise de sistemas inteligentes, com uma ampla gama de aplicações, uma vez que elas são flexíveis para adaptação e aprendizado. Modificando suas estruturas computacionais apresentam robustez na presença de ruído (dados errôneos ou incompletos), alta capacidade de generalização e recuperação de falhas (Fiszelew y García-Martínez S/D).

Entre as aplicações de maior importância das RNAs estão o reconhecimento de padrões, Sistemas Especialistas Conexionistas, Controle de

Processos, Séries temporais e Monitoramento. Cada uma destas aplicações envolve um estudo mais detalhado (Barreto 2002).

De acordo com Martín Del Brío e Sanz (1997), a classificação de imagens por RNAs baseia sua teoria sobre a imitação de RNBs. A aprendizagem da RNA envolve o uso de informação espectral oriunda dos pixels da imagem como padrões de treinamento, para os quais é atribuída uma determinada classe; esta classificação representa um método não paramétrico robusto e de bom desempenho quando os dados não seguem uma distribuição normal.

Segundo Triñanes et.al (1994), a aplicação de RNAs em tarefas de reconhecimento de padrões baseia-se nas seguintes considerações:

- Não requer hipóteses sobre a natureza explícita do conjunto de dados a ser classificado (por exemplo, uma distribuição normal).
- Uma RNA treinada é computacionalmente eficiente e pode atingir um alto grau de acurácia ao ser usada em classificação de imagens de satélite. Informação da textura da imagem pode ser introduzida na aprendizagem da rede, permitindo melhores resultados.
- O algoritmo de retropropagação (*backpropagation*) pode ser modificado para acelerar o processo de aprendizagem da RNA.

A utilização de RNAs apresenta-se como uma alternativa vantajosa aos classificadores baseados em conceitos estatísticos, já que podem-se obter resultados satisfatórios utilizando um número mínimo de amostras para conseguir a generalização. A flexibilidade dos algoritmos de classificação baseados em RNAs permite incluir diferentes tipos de variáveis, relacionadas com características espectrais e espaciais para a identificação de objetos (Andrade, Centeno y Araki 2002).

Para a classificação de uma imagem digital, a alternância das classes e amostras na entrada da RNA é recomendada. Isto otimiza a aprendizagem da rede tanto como diminui a quantidade de amostras requeridas para o treinamento, utilizando o algoritmo de retropropagação devido a possibilidade de variar os números de neurônios na camada oculta (Centeno y Botelho 2003).

Na sequência são apresentados alguns exemplos de classificação de imagens de satélite e detecção de alterações na vegetação usando RNA:

A aplicação de RNAs junto com técnicas de SIG para a predição de cobertura florestal numa área do estado do México, gerou valores satisfatórios para mais do 83% dos dados avaliados com a rede treinada. No trabalho, é percebida a eficiência do uso de RNAs em classificação de padrões com alta variabilidade, registrando melhores resultados do que os obtidos por métodos de classificação convencionais (Buendía, y otros 2002).

Segundo o trabalho de Fkirin, Badwai, e Mohamed (2009), o sistema de RNA para detecção de alterações na cobertura mostra um grande potencial em comparação com outras técnicas (razão, classificação). Especialmente, se as duas imagens não possuem balanço radiométrico, uma vez que as outras técnicas podem proporcionar uma regressão espúria na detecção de alterações.

De acordo com Argote, *et al.*, (2011), o modelo *Terra-i* utilizou RNAs e dados de índice de vegetação (NDVI) oriundos de imagens de satélite juntamente com dados de precipitação. O modelo foi capaz de prever a evolução da intensidade das medidas de vegetação com base na intensidade do verde anterior e medidas climáticas atuais. O objetivo do trabalho foi detectar mudanças significativas no habitat obtendo como resultado um valor de desmatamento médio anual de 60,363 ha / ano para o período de avaliação 2004- 2011 numa área de 129 mil ha aproximadamente do Perú.

Segundo o estudo realizado por Argote, *et al.*, (2010), a perda de floresta nativa cumulativa nacional detectada por *Terra-i*, no período 2004-2011 para Equador, é de aproximadamente 26 mil hectares, com a maior perda anual média nas províncias de *Napo* e *Esmeraldas*; 1250 e 761 ha/ano, respectivamente.

Não há uma técnica de detecção de mudança universalmente ideal. A escolha depende da aplicação. Mesmo a questão de qual técnica é melhor para uma aplicação em particular permanece geralmente aberta.

3.3.2 Neurônio Artificial

O neurônio artificial, célula ou autômato é um elemento que tem um estado interno, chamado nível de ativação, e recebe sinais que permitem, se necessário, mudar de estado (Isasi y Galván 2004).

Os neurônios têm a capacidade de alterar seu estado de ativação em

função do sinal de entrada recebido e das conexões sinápticas associadas; este estado é chamado de estado de ativação. A função que permite passar de um estado de ativação do neurônio para outro, a partir de sinais recebidos, é chamada função de ativação ou de transição. Os níveis de ativação não dependem de estados de ativação anteriores, no entanto, são dependentes das contribuições recebidas e os valores das conexões sinápticas. O estado de ativação total do neurônio é obtido da saída da função de transferência quando avaliada a soma ponderada de todas as entradas multiplicadas pelos respectivos pesos sinápticos (Isasi y Galván 2004).

Na figura 3 observa-se o nível de ativação do neurônio (y), a função de transferência ($f(\Sigma)$), a entrada total ao neurônio (Σ) e os pesos sinápticos (W_i).

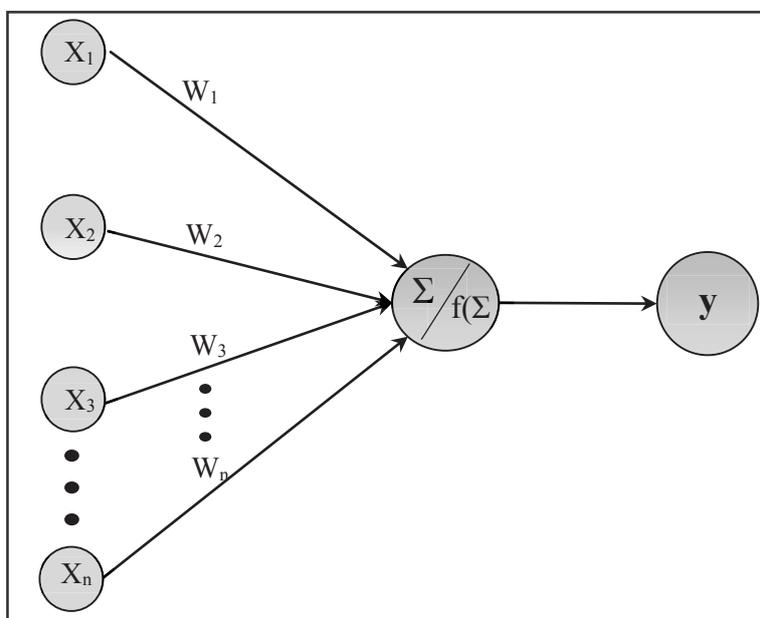


FIGURA 3 - ESQUEMA DE UMA UNIDADE TÍPICA DE PROCESSOS

FONTE: ADAPTADO DE (Isasi y Galván 2004)

A entrada total ao neurônio pode ser definida segundo a seguinte equação:

$$\Sigma = x_1 w_1 + x_2 w_2 + x_3 w_3 + \dots + x_n w_n \quad 3.3$$

Ou escrita em forma vetorial:

$$\Sigma = x^T w \quad 3.4$$

Onde:

x^T : corresponde ao vetor de entradas ao neurônio

w : corresponde ao vetor dos pesos sinápticos

Com estes valores pode-se calcular a saída do neurônio segundo a equação 3.5, aplicando-se à soma (Σ) da entrada e a função de transferência (f).

$$y = f(\Sigma) \quad 3.5$$

3.3.3 Funcionamento de uma RNA

As RNAs estão baseadas no comportamento e funcionamento das RNBs, estas capturam as informações como sendo estímulos, e em seguida, as processam e transmite para um sistema paralelo composto por elementos chamados neurônios. Porém, existem marcadas diferenças entre os sistemas biológicos e artificiais, sendo as mais importantes a complexidade das sinapses e a quantidade de pontos de interconexão inter-neurais. Os sistemas biológicos têm milhares de componentes e processos ativos de propagação de impulsos eletroquímicos, enquanto as conexões dos sistemas artificiais são simples, as entradas são processadas por uma soma ponderada para ser transferidas à função limiar (Isasi y Galván 2004).

Os impulsos eletroquímicos dos sistemas biológicos chegam aos neurônios em qualquer momento em que a sua reconfiguração ocorre, eles têm um funcionamento contínuo; no entanto, em sistemas artificiais pode-se dizer que o funcionamento é uma operação síncrona desde que a atualização dos seus parâmetros é realizada periodicamente e, portanto, sua reconfiguração também é de forma conjunta (Isasi y Galván 2004).

Outra diferença é o período de aprendizagem; enquanto as RNBs conseguem a aprendizagem num tempo relativamente curto e com um menor número de padrões mostrados, as RNAs precisam uma quantidade considerável de padrões de treinamento, a fim de chegar a um nível ótimo de aprendizagem e alcançar um nível tolerável de generalização; além disso, diferentes configurações devem ser testadas até conseguir o desempenho adequado da RNA (Isasi y Galván 2004).

3.3.4 Estrutura da RNA

Uma RNA está composta por camadas ou níveis interligados por meio dos quais as informações são transferidas. A forma como os neurônios são ligados entre si é chamado de arquitetura de rede ou padrão de conectividade. A estrutura básica de interligação entre as células é de multicamada. A figura 4 apresenta uma estrutura clássica conhecida como uma rede de retropropagação. Na primeira camada ou camada de entrada, a informação do exterior (valores padrões) é recebida, em seguida, tem-se as ditas camadas ocultas ou intermediárias, o número de camadas ocultas depende da configuração de RNA usada e do tipo de problema a ser resolvido. Finalmente temos o nível de saída cujos neurônios processam as saídas geradas pelas camadas ocultas e geram a saída da rede (Isasi y Galván 2004).

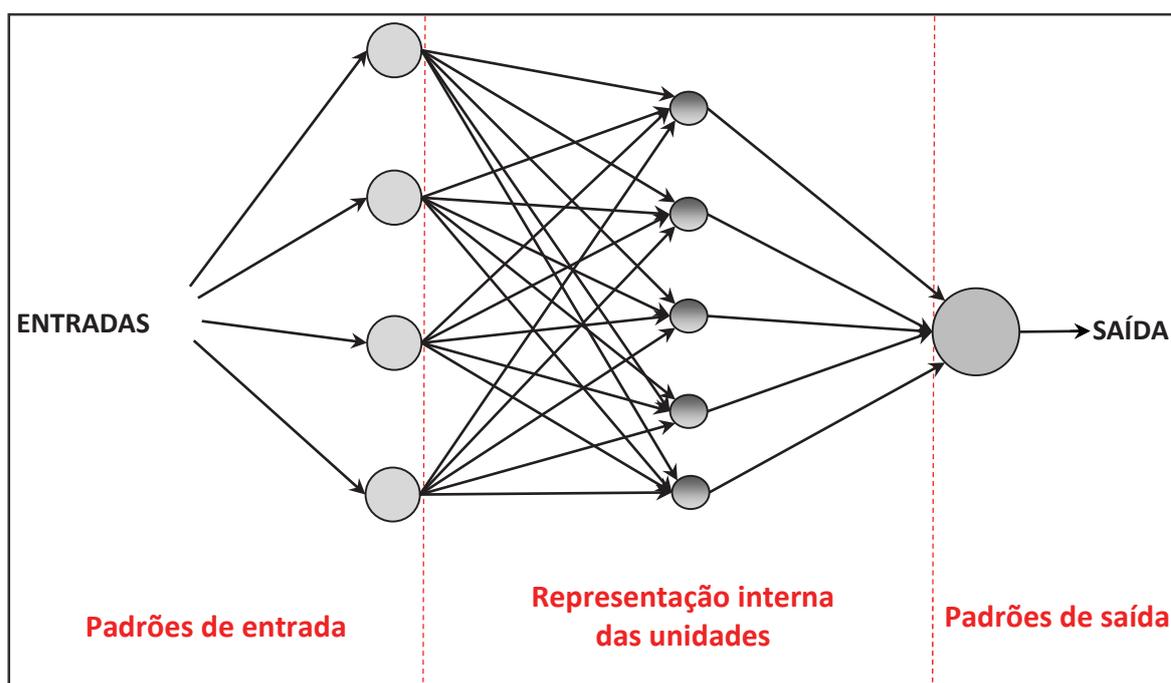


FIGURA 4 - ESQUEMA DE UMA REDE DE TRÊS CAMADAS INTERCONECTADAS

FONTE: ADAPTADO DE ISASI E GALVÁN (2004)

As informações recebidas pelos neurônios em cada camada da rede são avaliadas por uma função de transferência, antes de ser enviadas para os neurônios do próximo nível ou camada (Haykin 2001).

Segundo Haykin (2001), cada interconexão entre as unidades do sistema atua como um canal de comunicação através do qual circulam os valores numéricos de um neurônio para outro, esses valores são avaliados pelos pesos sinápticos das conexões que são iterativamente modificados durante a fase de aprendizagem até que a rede assimile as informações recebidas durante o treinamento. Quando isso acontece, a rede está pronta para receber padrões de entrada que não estiveram presentes no treinamento.

A seguinte expressão vetorial representa o funcionamento de uma RNA (Barreto 2002):

$$\vec{y} = f_2(f_1(\vec{X}\vec{\omega}_1)\vec{\omega}_2) \quad 3.6$$

Onde:

\vec{X} =Entrada à rede neural (conjunto de entradas)

\vec{y} =Saída da rede neural

f_1 =Função de transferência da camada oculta

$\vec{\omega}_1$ =Pesos sinápticos para a camada entrada-camada oculta

f_2 =Função de transferência da camada de saída

$\vec{\omega}_2$ =Pesos sinápticos para a camada oculta-camada de saída

O vetor \vec{X} constitui o conjunto de entradas da rede, que vai ser multiplicado por um vetor de peso $\vec{\omega}_1$, antes de ser transferido para a camada oculta, este resultado passa por uma função de transferência f_1 antes de ser enviado para a camada seguinte, aqui serão multiplicados pelo vetor de peso $\vec{\omega}_2$ correspondente aos conexões neurais entre a camada oculta e a camada de saída, finalmente, o produto é avaliado pela função de transferência f_2 dos neurônios da camada de saída (Barreto 2002).

3.3.5 Aprendizagem da Rede Neural Artificial

A aprendizagem pode ser entendida como a aquisição de conhecimento através da experiência, devido a estímulos externos. A aprendizagem é a parte mais importante das RNAs. A sua capacidade de resolver problemas está intimamente relacionada com seu esquema de aprendizagem baseado em

padrões. O conjunto de padrões de treinamento deve ser significativo, ou seja a quantidade de padrões apresentado durante o treinamento tem que ser suficiente para que a rede seja capaz de adaptar seus pesos sinápticos. O conjunto de dados de treinamento tem que ser também representativo, os padrões devem ser diversos, caso contrário, a RNA vai se especializar nos tipos de padrões apresentados com maior frequência e não vai conseguir uma capacidade de generalização satisfatória. Todos os padrões devem estar devidamente representados no conjunto de treinamento. A determinação dos valores adequados para os pesos, estabelece o aprendizado da RNA, permitindo-lhe sucesso na resolução do problema (Basogain 2008).

Durante o processo de aprendizagem, os valores padrão são introduzidos na rede individualmente ou simultaneamente, os pesos das conexões são modificados de acordo com um esquema de aprendizagem baseado num algoritmo. O fim do processo é estabelecido segundo um critério de convergência determinado pelo tipo de RNA usada. A aprendizagem finaliza se o critério é atingido, caso contrário o processo é repetido e todos os padrões são novamente introduzidos iterativamente (Isasi y Galván 2004).

O fim da aprendizagem da RNA pode ser determinado segundo os seguintes critérios (Isasi y Galván 2004):

- Definir o número de ciclos ou repetições: Antes de introduzir o conjunto padrão para o treinamento da RNA, estabelecer quantas vezes este processo será repetido. Quando o número de repetições é atingido, o processo de aprendizagem finaliza.
- Quando o erro gerado pela rede é inferior que um erro estabelecido a priori: um valor aceitável de erro é predefinido e o processo de aprendizagem finaliza quando o erro da RNA é inferior a este valor. O risco deste critério é que a rede não consiga atingir à condição, é importante então estabelecer um critério adicional.
- Quando a alteração dos valores dos pesos é irrelevante, ou seja, se as alterações nos pesos sinápticos não são significativas, então o processo de aprendizagem finaliza. Neste caso, também existe o risco de não ter convergência, e é necessário definir uma condição adicional para finalizar

o processo.

Existem três tipos de esquema de aprendizagem:

- Aprendizado Supervisionado: Este esquema de aprendizagem contém dois componentes, as entradas para a rede ou conjunto de treinamento e suas saídas relacionadas. As saídas geradas em função das entradas correspondentes são comparadas com as saídas esperadas ou ideais (*targets*); a diferença ou erro gerado desta comparação é usada pelo algoritmo de aprendizagem que mediante realimentação da rede realiza o ajuste dos pesos sinápticos anteriores. Este processo é repetido até que a saída gerada pela RNA seja a mais próxima possível da saída desejada (minimização do erro). À medida que a saída da rede aproxima-se da saída desejada, a mudança nos pesos sinápticos continuará a diminuir (Isasi y Galván 2004).
- Aprendizagem não supervisionada: Neste tipo de aprendizagem o conjunto de dados de treinamento de entrada não tem saídas associadas, o processo de aprendizagem não é guiado por um conjunto de saídas desejadas; portanto, utiliza só os padrões de dados de entrada para realizar o treinamento da rede. Assim o algoritmo de aprendizagem irá ajustar os valores dos pesos sinápticos em função do grau de familiaridade dos dados de treinamento e da informação interna da rede. Este tipo de modelo é conhecido como sistema auto organizado (Isasi y Galván 2004).
- Aprendizado por reforço: É semelhante ao tipo supervisionado, sua principal característica é garantir a capacidade de generalização da rede considerando que a obtenção de um pequeno erro entre a saída desejada e a saída da RNA não garante que quando ingressados padrões não incluídos no treinamento, eles sejam devidamente classificados. É possível que a rede tenha sido sobre treinada e não seja capaz de resolver o problema em forma geral. Uma solução é dividir o grupo em dois subgrupos de treinamento; um deles para treinamento puro (ajustar os pesos usando o método supervisionado), e outro para validação (calcular o erro gerado pela rede, estes dados não participam do treinamento). Assim, obtém-se uma medida mais confiável da capacidade de

generalização da RNA (Isasi y Galván 2004).

3.3.6 Modelos Neurais

3.3.6.1 Modelo neural de McCulloch-Pitts

Este modelo foi o primeiro considerado como uma RNA, proposto por Warren McCulloch e Walter Pitts, em 1943; a sua estrutura e funcionamento imitava de uma forma simples o funcionamento dos neurônios cerebrais. Aceitava entradas binárias e as saídas produzidas ficavam do mesmo tipo, ou seja, considerava apenas dois estados, desligado (0), e ligado (1) (Barreto 2002).

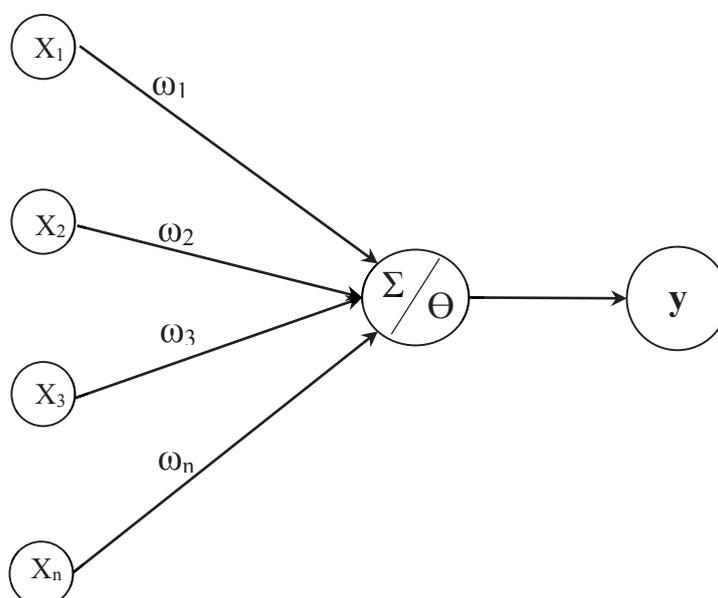


FIGURA 5 - MODELO DE NEURÔNIO ARTIFICIAL DE MCCULLOCH-PITTS

FONTE: Adaptado de Isasi y Galván (2004)

3.3.6.2 *Perceptron*

Este modelo foi desenvolvido para tarefas de classificação automática, os parâmetros das conexões sinápticas definem superfícies discriminantes que ajudam a classificar um conjunto de padrões. (Basogain 2008).

A classificação é feita através de um aprendizado supervisionado. Um parâmetro adicional chamado limiar (Θ) é relacionado com a saída do *Perceptron*. A figura 6 mostra um *perceptron* de camada única, as entradas (X_1 ,

X_2, X_3, \dots, X_n) e a saída (y), a função de transferência tipo limiar (Θ) usado como fator de transferência para a saída (Basogain 2008).

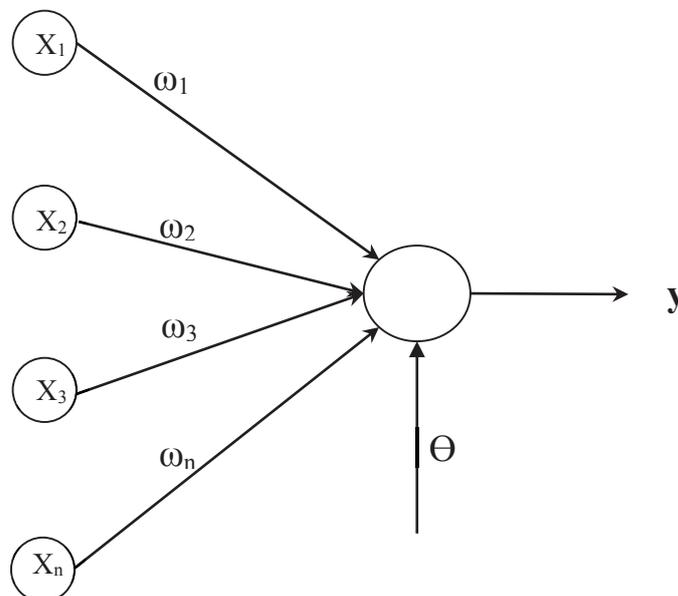


FIGURA 6 - ARQUITETURA DE UM PERCEPTRON COM N ENTRADAS E UMA SAÍDA

FONTE: Adaptado de Isasi y Galván (2004)

3.3.6.3 ADALINE (*Adaptive Linear Neuron*)

O *Perceptron* baseia sua aprendizagem em padrões de entrada cujas saídas são consideradas binárias. Os problemas que não podem ser resolvidos a partir da perspectiva de uma saída binária são abordados pelas redes neurais tipo *ADALINE*. As saídas deste tipo de rede não são avaliadas por uma função limiar ao contrário do *Perceptron*, por conseguinte, as saídas geram valores reais que são comparados com as saídas desejadas.

A regra de aprendizagem para redes *ADALINE* considera a diferença entre a saída gerada e a saída desejada (*target*) fornecida durante o treinamento; isso é conhecido como Regra Delta (Basogain 2008).

$$\text{Regra Delta} = d^p - y^p \quad 3.7$$

Onde:

d^p = saída esperada para o padrão p

y^p = saída da rede para o padrão p

As diferenças entre as saídas geradas pela rede e as saídas esperadas não podem ser eliminadas por completo, o objetivo do processo de aprendizagem é o de minimizar o erro global cometido pela rede para os dados de treinamento.

Normalmente considera-se o erro quadrático médio como medida de erro global e é definido por (Basogain 2008):

$$E = \frac{1}{N} \sum_{p=1}^N (d^p - y^p)^2 \quad 3.8$$

Onde N é o número total de padrões ou entradas disponíveis para o treinamento da rede. O processo global de aprendizagem deve minimizar a função de erro global.

3.3.7 Problemas não lineares

Segundo Isasi e Galván (2004), os modelos de RNAs como *Perceptron* e *ADALINE* têm limitações na resolução de problemas. Eles foram a base para o início do estudo de sistemas inteligentes, no entanto, não são considerados solucionadores gerais de problemas. Quando o problema de classificação não é linearmente separável, a solução será necessariamente não-linear. O problema pode ser resolvido através da adição de mais camadas à RNA, adquirindo desta forma um caráter não linear.

Para as redes de uma camada, o ajuste dos pesos é realizado com base nos erros registrados na saída, porém, já que as saídas esperadas oriundas do conjunto de treinamento só estão disponíveis para os neurônios da camada de saída, o cálculo do erro não pode ser realizado nos neurônios das camadas ocultas e, portanto, não pode ser feito o ajuste dos pesos sinápticos para as conexões neurais correspondentes. A regra delta modificada para sua aplicação em RNAs multicamada recebe o nome de Regra Delta Generalizada, a modificação da regra permite que seja possível atualizar os pesos de todas as camadas da rede (camada de saída e camadas ocultas). O *Perceptron* multicamada foi um dos primeiros modelos de RNA em usar esta variação do algoritmo de treinamento (Isasi y Galván 2004).

3.3.8 *Perceptron* Multicamada

O *Perceptron* Multicamada é uma generalização do *perceptron* simples, inclui camadas internas chamadas camadas ocultas na arquitetura da rede, resolvendo assim o problema da separabilidade não linear. O algoritmo ajusta os pesos sinápticos das camadas ocultas e de saída da rede mediante o uso da Regra Delta Generalizada. Este algoritmo ajusta os pesos sinápticos das camadas internas, retropropagando os erros registrados na camada de saída. O número de camadas ocultas utilizadas depende das características do problema proposto. O número de células ou de neurônios contidos na camada de saída e o número de entradas da RNA, dependem do tipo de problema a ser resolvido; enquanto o número de neurônios nas camadas ocultas é definido durante o treinamento e não existe uma regra para sua determinação (Isasi y Galván 2004).

A informação contida neste tipo de rede é propagada para trás (*feedforward*). A interconexão ocorre entre todos os neurônios da camada anterior e da próxima camada. Cada conexão é associada com um valor que representa um peso sináptico e todos os neurônios são afetados por um valor limiar, este limiar atua como uma conexão adicional, cujo valor de entrada é 1. Os padrões de entrada em um *perceptron* multicamadas são propagados como segue (Basogain 2008):

Ativação dos neurônios da camada de saída

$$a_i = f_1\left(\sum_{j=1}^{j=m}(x_j w_{ij})\right) \quad 3.9$$

Ativação dos neurônios da camada oculta

$$a_j = f_2\left(\sum_{k=1}^{k=n}(x_k w_{jk})\right) \quad 3.10$$

Onde:

x_j = neurônios da camada oculta

x_k = neurônios da camada de entrada

w_{ij} = pesos da camada de oculta

w_{jk} = pesos da camada de entrada

m = número de neurônios da camada oculta

n = número de neurônios da camada de entrada

f_1 = função de ativação da camada de saída

f_2 = função de ativação da camada oculta

3.3.9 Funções de transferência

As funções de transferência mais comumente usadas na rede tipo *Perceptron* Multicamadas são a função sigmoial e a função tangente hiperbólica.

3.3.9.1 Função sigmoial

A função 3.11 define as saídas no intervalo $(0 ; 1)$, é representada por uma curva assintótica aproximando-se de forma contínua e infinita às retas definidas por $y = 0$ e $y = 1$, mas sem interceptá-las. Figura 7.

$$f = \frac{1}{1+e^{-x}}$$

3.11

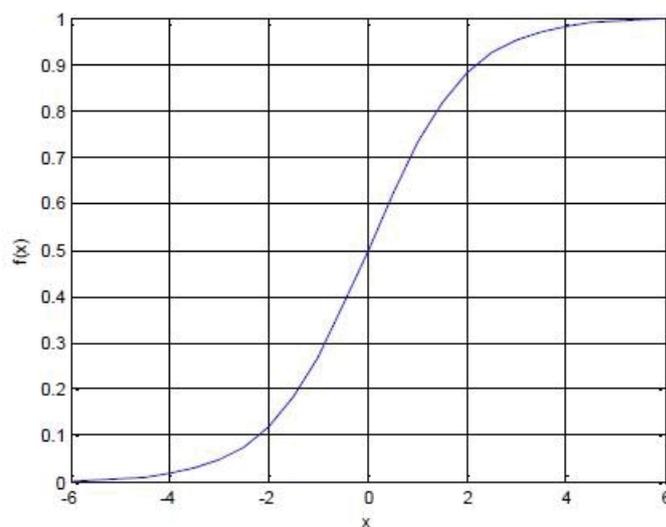


FIGURA 7 - FUNÇÃO SIGMOIAL

FONTE: Adaptado de(Isasi y Galván 2004)

3.3.9.2 Função tangente hiperbólica

A função 3.12 define as saídas no intervalo -1 a + 1, é representada por uma curva assintótica aproximando-se de forma contínua e infinita às retas definidas por $y = 1$ e $y = -1$, mas sem interceptá-las. Figura 8.

$$f = \frac{1-e^{-x}}{1+e^{-x}} \quad 3.12$$

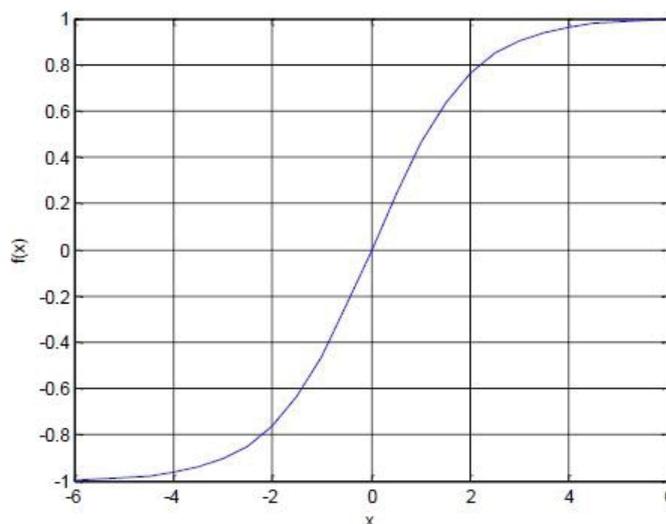


FIGURA 8 - FUNÇÃO TANGENTE HIPERBÓLICA

FONTE: Adaptado de (Isasi y Galván 2004)

Geralmente utiliza-se a mesma função de ativação para todas as camadas de uma RNA, no entanto, dependendo do problema é possível usar uma função de ativação diferente para os neurônios da camada de saída, podendo ser uma função de tipo limiar ou uma função identidade (Isasi y Galván 2004).

A arquitetura e capacidade de aprendizagem da RNA estão intimamente relacionadas com as funções de ativação utilizadas e com o número de camadas ocultas e de neurônios contidos em cada camada (Isasi y Galván 2004).

O esquema na figura 9, representa uma rede de tipo *perceptron* multicamada onde se pode observar as diferentes conexões e a propagação da informação através das camadas.

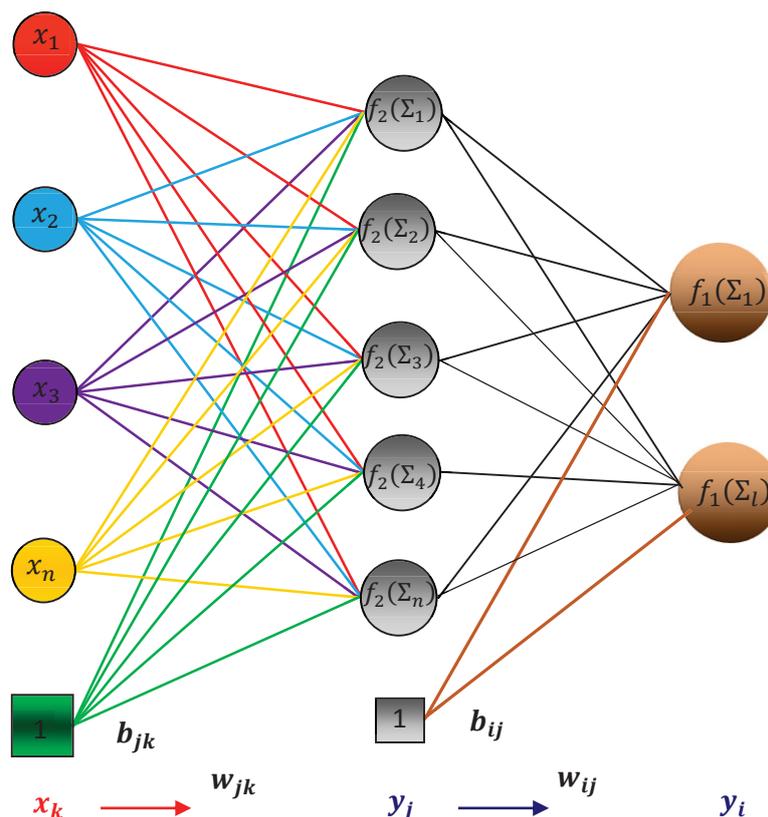


FIGURA 9 - PROPAGAÇÃO DA INFORMAÇÃO EM UM PERCEPTRON MULTICAMADA

FONTE: A Autora (2015)

3.3.10 Algoritmos de treinamento de uma RNA

Para que o treinamento da RNA seja realizado, é indispensável utilizar um algoritmo capaz de modificar os pesos sinápticos em função dos erros gerados pela RNA. O algoritmo usado, em geral dependerá do tipo de problema que tem que ser resolvido e da arquitetura de RNA que será usada.

Nesta seção são apresentados os principais algoritmos de treinamento para as RNA citadas neste trabalho.

3.3.10.1 Algoritmo de Treinamento do *Perceptron Multicamada*

Em um *perceptron* o produto das entradas associadas com as conexões sinápticas determina a variação dos pesos durante o treinamento segundo a Equação. 3.13 (Isasi y Galván 2004).

$$\Delta\omega_i = x_i^p d^p \quad 3.13$$

Onde:

x_i^p = entrada i com um padrão de treinamento p

d^p = classe associada ao padrão de treinamento, pode ter valores entre (+1 ; -1)

$\Delta\omega_i$ = variação dos pesos sinápticos

Na figura 10 é mostrado como uma rede de tipo *perceptron* é capaz de resolver a função lógica *AND*. Valores iniciais aleatórios para os pesos e o limiar são definidos, então um ajuste desses valores é realizado seguindo o algoritmo de aprendizagem até que os padrões são classificados corretamente. (Isasi y Galván 2004).

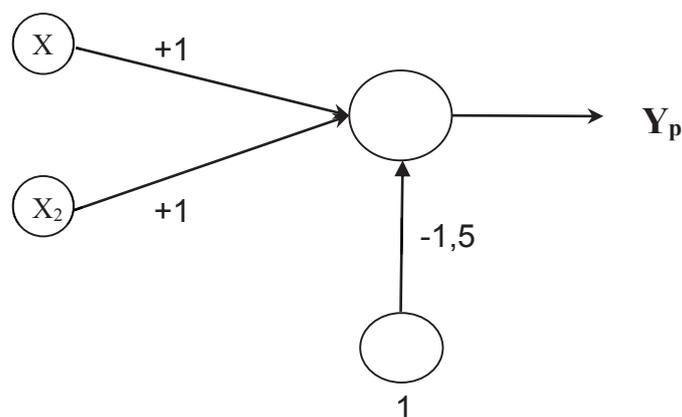


FIGURA 10 - CONFIGURAÇÃO DO PERCEPTRON PARA A SOLUÇÃO DA FUNÇÃO LÓGICA AND

FONTE: ADAPTADO DE (Isasi y Galván 2004)

3.3.10.2 Algoritmo de Retropropagação

O algoritmo de retropropagação baseia-se na Regra Delta Generalizada, calcula as variações para os pesos sinápticos das camadas ocultas retropropagando os erros gerados na saída da rede (Haykin 2001).

O aprendizado da rede utiliza um algoritmo cujo princípio é a minimização da função de erro em função dos parâmetros livres da rede (pesos sinápticos) (Haykin 2001).

A função de erro mais comumente usada para RNAs é o Erro Quadrático

Médio (RMS, siglas em inglês), e pode ser calculado segundo a seguinte expressão:

$$e_p = \frac{1}{2} \sum_{i=1}^l (d_i - y_i)^2 \quad 3.14$$

Onde:

e_p = erro de treinamento para o padrão p

p = subíndice dos padrões de treinamento

i = subíndice dos neurônios da camada de saída

l = número dos neurônios da camada de saída

d = valor das saídas esperadas

y = valor das saídas calculadas pela rede para um padrão de treinamento p

O erro global da RNA, utilizando todos os padrões de treinamento é calculado por:

$$E = \frac{1}{N} \sum_{p=1}^N e_p^2 \quad 3.15$$

Onde:

E = erro global da rede neural

N = número de padrões de treinamento

e_p = erro de treinamento para o padrão p

p = subíndice dos padrões de treinamento

A saída de cada neurônio na camada de saída é expressa pela fórmula:

$$y_i = f_1(a_i) \quad 3.16$$

Onde:

f_i = função de ativação nos neurônios da camada de saída

e a_i corresponde a seguinte expressão:

$$a_i = \sum_{j=1}^m (y_j w_{ij}) - b_{ij} \quad 3.17$$

Sendo:

i = subíndice dos neurônios da camada de saída

j = subíndice dos neurônios da camada oculta

m = número de neurônios da camada oculta

y_j = saídas dos neurônios da camada oculta

w_{ij} = conexões sinápticas entre os neurônios da camada oculta e a camada de saída

b_{ij} = bias para os neurônios da camada de saída

3.3.11 Métodos para Minimizar Funções do Erro

O objetivo do método de mínimos quadrados é encontrar o melhor ajuste para um conjunto de dados, de tal modo que a soma dos quadrados dos desvios entre cada ponto dado e o modelo seja mínima. A diferença entre a curva ajustada e cada um dos dados são chamados resíduos (Madsen, Nielsen y Tingleff 2004).

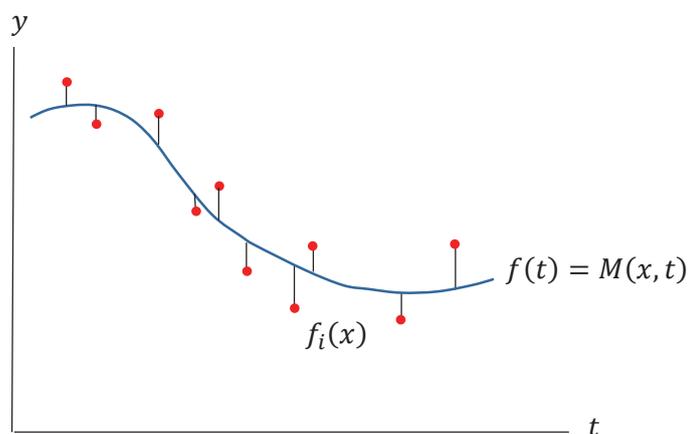


FIGURA 11 - AJUSTAMENTO DE PONTOS MEDIANTE UMA FUNÇÃO M

FONTE: Adaptado de *Carrión*, 2013.

A função a seguir representa a diferença entre o valor verdadeiro ou valor real e o valor estimado pelo modelo M para a variável y em função do valor da variável t . Os parâmetros que definem o modelo M são representados por x .

$$f_i(x) = y_i - M(x, t_i) \quad 3.18$$

A soma das diferenças ao quadrado dos resíduos gerados entre os valores de y_i e $t_i = f(x_i)$ definem a função que será minimizada ($F(x)$).

$$F(x) = \frac{1}{2} \sum_{n=1}^U (f_n(x))^2 = \frac{1}{2} [(f_1(x))^2 + (f_2(x))^2 + (f_3(x))^2 + \dots + (f_U(x))^2] \quad 3.19$$

Onde:

U = número de dados

n = subíndice de cada ponto

Entre os diferentes métodos para a resolução de problemas de mínimos quadrados não lineares estão (Díaz 1998):

- Método de *Newton*
- Método de Gauss-Newton
- Método de *Levenberg-Marquardt*

3.3.11.1 Método de Newton

Seja x^* o ponto crítico da função F , então a primeira derivada da função é igual ao zero $F'(x^*) = 0$ (Díaz 1998).

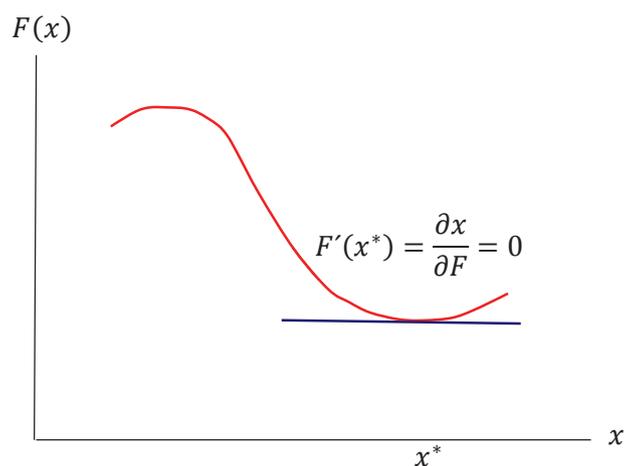


FIGURA 12 - MINIMIZAÇÃO DE UMA FUNÇÃO DE ERRO PELO MÉTODO DE NEWTON

FONTE: Adaptado de (Carrión 2013)

$F'(x^*) = 0$ é um ponto crítico da função F porque a pendente no ponto desejado é nula.

Se expandirmos a função com uma série de Taylor até o segundo termo, temos:

$$F(x + h) = F(x) + F'(x)(x + h - x) = F(x) + F'(x)h \quad 3.20$$

O fator h é incluído na análise, este fator representa as alterações feitas nos parâmetros do modelo (x) na busca do mínimo da função de erro, como é mostrado na figura 13 (Díaz 1998).

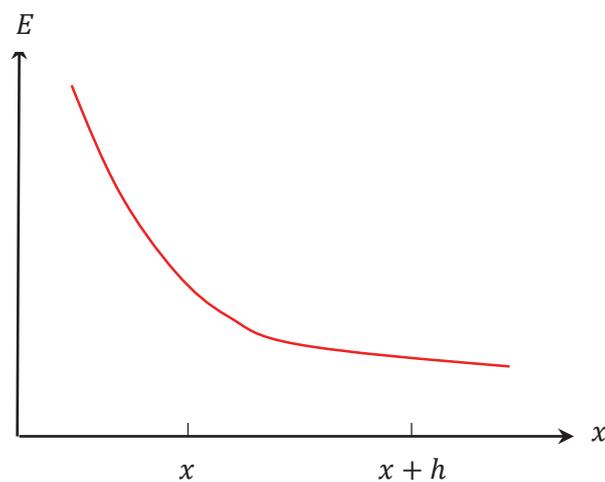


FIGURA 13 - MINIMIZAÇÃO DA FUNÇÃO DE ERRO E

FONTE: Adaptado de (Carrión 2013)

A partir da equação 3.20 (Serie de Taylor) segue-se que:

$$F'(x + h) = F'(x) + F''(x)h \quad 3.21$$

Sabendo que x^* é o ponto em que a pendente de $F(x)$ é nula; portanto, considerando que h é o valor que será adicionado a x na busca do x^* , obedece à seguinte condição:

$$F'(x + h) = 0 \rightarrow x + h = x^* \quad 3.22$$

Assim:

$$F'(x) + F''(x)h = 0 \quad 3.23$$

Onde:

$F'(x)$ = matriz jacobiana (J)

$F''(x)h$ = matriz hessiana (H)

Considerando 3.22 temos que:

$$F''(x)h = -F'(x) \quad 3.24$$

$$h_n = -\frac{F'(x)}{F''(x)} = -\frac{J}{H} \quad 3.25$$

$$h_n = -\frac{F'(x)}{F''(x)} = -\frac{\begin{bmatrix} \frac{\partial F}{\partial x_1} & \frac{\partial F}{\partial x_2} & \frac{\partial F}{\partial x_3} & \dots & \frac{\partial F}{\partial x_n} \end{bmatrix}}{\begin{bmatrix} \frac{\partial^2 F}{\partial x_1 \partial x_1} & \frac{\partial^2 F}{\partial x_1 \partial x_2} & \frac{\partial^2 F}{\partial x_1 \partial x_3} & \dots & \frac{\partial^2 F}{\partial x_1 \partial x_n} \\ \frac{\partial^2 F}{\partial x_2 \partial x_1} & \frac{\partial^2 F}{\partial x_2 \partial x_2} & \frac{\partial^2 F}{\partial x_2 \partial x_3} & \dots & \frac{\partial^2 F}{\partial x_2 \partial x_n} \\ \cdot & \cdot & \cdot & \dots & \cdot \\ \cdot & \cdot & \cdot & \dots & \cdot \\ \frac{\partial^2 F}{\partial x_n \partial x_1} & \frac{\partial^2 F}{\partial x_n \partial x_2} & \frac{\partial^2 F}{\partial x_n \partial x_3} & \dots & \frac{\partial^2 F}{\partial x_n \partial x_n} \end{bmatrix}} \quad 3.26$$

Pelo método de Newton, temos que o novo x é dado por:

$$x_2 = x_1 + h_n \quad 3.27$$

Os métodos de *Gauss-Newton* e *Levenberg-Marquardt* têm sido propostos a fim de resolver o problema da utilização da Matriz *Hessiana* que é extremamente complexa (Madsen, Nielsen y Tingleff 2004).

3.3.11.2 Método de Gauss-Newton

Lembrando que segundo a Eq. 3.18:

$$f_i(x) = y_i - M(x, t_i)$$

Temos que:

$$f(x) = \begin{bmatrix} f_1(x) \\ f_2(x) \\ f_3(x) \\ \vdots \\ f_m(x) \end{bmatrix} = \begin{bmatrix} y_1 - M(x, t_1) \\ y_2 - M(x, t_2) \\ y_3 - M(x, t_3) \\ \vdots \\ y_m - M(x, t_m) \end{bmatrix} \quad 3.28$$

A função é expandida em uma série de Taylor até o segundo termo:

$$f(x + h) \approx l(h) \equiv f(x) + f'(x)^*(x + h - x) = f(x) + f'(x)h \quad 3.29$$

A figura 14 representa a função f (função de erro) dependendo dos parâmetros do modelo M

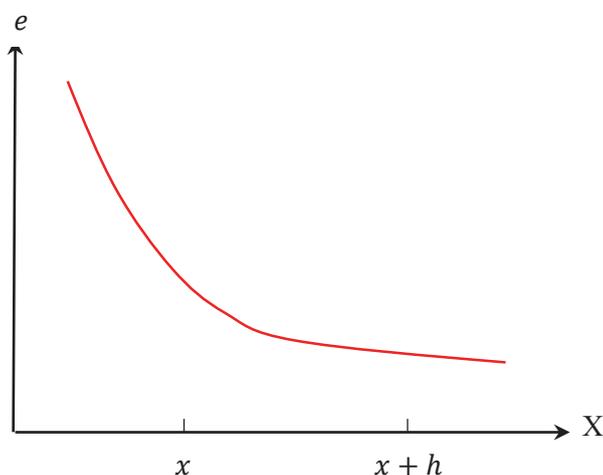


FIGURA 14 - MINIMIZAÇÃO DA FUNÇÃO DE ERRO e

FONTE: Adaptado de (Carrión, 2013).

As funções de f são desenvolvidas segundo a série de Taylor a seguir:

$$\begin{aligned} f_1(x + h) &= f_1(x) + \frac{\partial f_1}{\partial x_1} \Delta x_1 + \frac{\partial f_1}{\partial x_2} \Delta x_2 + \frac{\partial f_1}{\partial x_3} \Delta x_3 + \cdots + \frac{\partial f_1}{\partial x_n} \Delta x_n \\ f_2(x + h) &= f_2(x) + \frac{\partial f_2}{\partial x_1} \Delta x_1 + \frac{\partial f_2}{\partial x_2} \Delta x_2 + \frac{\partial f_2}{\partial x_3} \Delta x_3 + \cdots + \frac{\partial f_2}{\partial x_n} \Delta x_n \\ f_3(x + h) &= f_3(x) + \frac{\partial f_3}{\partial x_1} \Delta x_1 + \frac{\partial f_3}{\partial x_2} \Delta x_2 + \frac{\partial f_3}{\partial x_3} \Delta x_3 + \cdots + \frac{\partial f_3}{\partial x_n} \Delta x_n \\ &\vdots \\ f_m(x + h) &= f_m(x) + \frac{\partial f_m}{\partial x_1} \Delta x_1 + \frac{\partial f_m}{\partial x_2} \Delta x_2 + \frac{\partial f_m}{\partial x_3} \Delta x_3 + \cdots + \frac{\partial f_m}{\partial x_n} \Delta x_n \end{aligned} \quad 3.30$$

Da expressão anterior podemos extrair em forma matricial

$$f'(x) = \begin{bmatrix} \frac{\partial f_1}{\partial x_1} & \frac{\partial f_1}{\partial x_2} & \frac{\partial f_1}{\partial x_3} & \cdots & \frac{\partial f_1}{\partial x_n} \\ \frac{\partial f_2}{\partial x_1} & \frac{\partial f_2}{\partial x_2} & \frac{\partial f_2}{\partial x_3} & \cdots & \frac{\partial f_2}{\partial x_n} \\ \frac{\partial f_3}{\partial x_1} & \frac{\partial f_3}{\partial x_2} & \frac{\partial f_3}{\partial x_3} & \cdots & \frac{\partial f_3}{\partial x_n} \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ \frac{\partial f_m}{\partial x_1} & \frac{\partial f_m}{\partial x_2} & \frac{\partial f_m}{\partial x_3} & \cdots & \frac{\partial f_m}{\partial x_n} \end{bmatrix} \quad 3.31$$

E:

$$h = \begin{bmatrix} \Delta x_1 \\ \Delta x_2 \\ \Delta x_3 \\ \vdots \\ \Delta x_n \end{bmatrix} \quad 3.32$$

Onde

$f'(x)$ = matriz jacobiano $J(x)$

h = passo do método de Gauss-Newton

Assim, é calculado h e com isto consegue-se a condição: $F'(x^*) = 0$.
(Díaz 1998).

Lembrando que:

$$F(x) = \frac{1}{2} [f(x)]^T f(x)$$

$$f(x+h) \approx l(h) \equiv f(x) + f'(x)h$$

$$f(x+h) \approx l(h) \equiv f(x) + J(x)h$$

Assim:

$$F(x+h) \approx L(h) \equiv \frac{1}{2} [f(x+h)]^T f(x+h) = \frac{1}{2} [l(h)]^T l(h) \quad 3.33$$

Para simplificar, temos:

$$f(x) = f$$

$$J(x) = J$$

Com o qual temos que:

$$l(h) = f + Jh$$

Por tanto:

$$L(h) = \frac{1}{2}(f + Jh)^T(f + Jh)$$

$$L(h) = \frac{1}{2}f^T f + \frac{1}{2}f^T Jh + \frac{1}{2}h^T J^T f + \frac{1}{2}h^T J^T Jh$$

$$L(h) = F(x) + h^T J^T f + \frac{1}{2}h^T J^T Jh \quad 3.34$$

Iguala-se ao 0 a primeira derivada de $L(h)$ a fim de encontrar seu ponto crítico:

$$L'(h) = 0 \quad 3.35$$

Então:

$$L'(h) = \frac{\partial F(x)}{\partial h} + \frac{\partial(h^T J^T f)}{\partial h} + \frac{1}{2} \left(\frac{\partial(h^T J^T Jh)}{\partial h} \right) \quad 3.36$$

A derivada de $F(x)$ com respeito a h , é zero, desde que a função F não tem termos em h , então:

$$\frac{\partial F(x)}{\partial h} = 0$$

Por tanto:

$$L'(h) = \frac{\partial(h^T J^T f)}{\partial h} + \frac{1}{2} \left(\frac{\partial(h^T J^T Jh)}{\partial h} \right) = J^T f + J^T Jh \quad 3.37$$

Agora:

$$L''(h) = (J^T f)' + (J^T Jh)' \quad 3.38$$

Sabendo que $L'(h) = 0$, temos que:

$$J^T f + J^T Jh = 0 \quad 3.39$$

$$J^T Jh_{gn} = -(J^T f) \quad 3.40$$

$$h_{gn} = -\frac{J^T f}{J^T J} \quad 3.41$$

Usando o método de *Gauss-Newton*, temos que o novo x é dado por:

$$x_2 = x_1 + h_{gn} \quad 3.42$$

Embora o método de *Gauss-Newton* seja uma forma mais adequada para resolver a matriz *Hessiana*, não garante que o inverso dessa matriz existe, o que é necessário para o cálculo de h_{gn} .

3.3.11.3 Método Levenberg Marquardt

Este método apresenta uma variação do método de *Gauss-Newton*, o termo μI é adicionado; sendo μ o parâmetro de *Damping*; e I é a matriz identidade (Madsen, Nielsen y Tingleff 2004).

Lembrando que:

$$h_{gn} = -\frac{J^T f}{J^T J}$$

Temos:

$$(J^T J + \mu I)h_{lm} = -g$$

Onde:

$$g = J^T f \quad 3.43$$

$$\mu \geq 0$$

Outro parâmetro chamado *gain ratio* (Taxa de ganho) a fim de modificar μ é adicionado durante as iterações (Madsen, Nielsen y Tingleff 2004).

$$\rho = \frac{F(x) - F(x+h_{lm})}{L(0) - L(h_{lm})} \quad 3.44$$

Temos:

$$si \begin{cases} F(x) - F(x + h_{lm}) > 0 \rightarrow \rho > 0 \\ F(x) - F(x + h_{lm}) < 0 \rightarrow \rho < 0 \end{cases}$$

Assim:

- Se $\rho < 0 \rightarrow F(x) < F(x + h_{lm})$

Temos que $v = 2v$ y $\mu = \mu v$. É inicializado com $v=2$

- Si $\rho > 0 \rightarrow F(x) > F(x + h_{lm})$

$$\mu = \mu^* \max\left(\frac{1}{3}; 1 - (2\rho - 1)^3\right) \quad 3.45$$

Do exposto segue-se que quanto maior for o valor de ρ irá diminuir o valor de μ aumentando o passo do método e vice-versa.

Com base na formula 3.41, tem-se:

$$h_{lm} = -\frac{J^T f}{J^T J + \mu I} \quad 3.46$$

Que é o passo do método de *Levenberg-Marquardt*

4 MATERIAIS E MÉTODOS

Neste capítulo serão apresentados os materiais e metodologia proposta neste trabalho para a detecção de alterações na vegetação.

A figura 15 mostra o processo geral seguido para a detecção de alterações na cobertura vegetal.

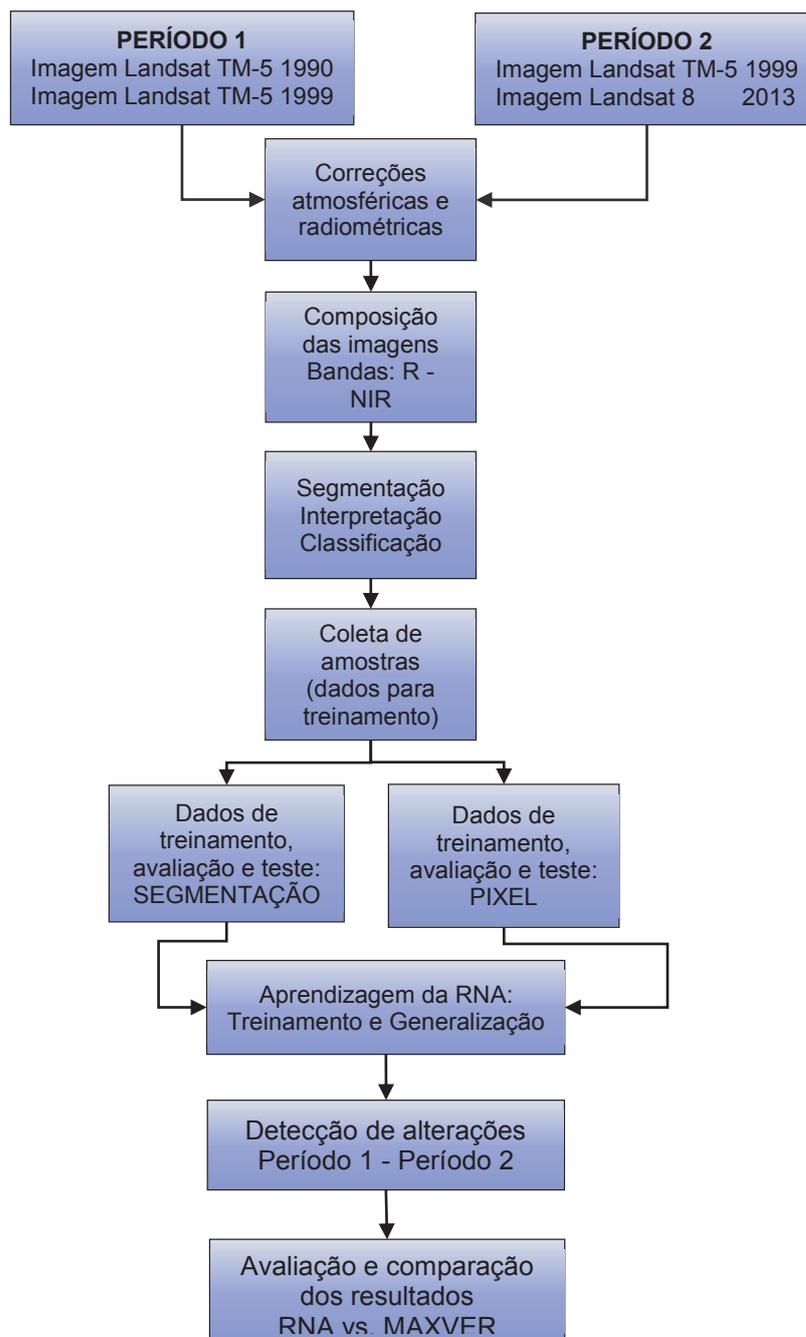


FIGURA 15 - ESQUEMA GERAL DO PROCESSO A SEGUIR PARA DETECÇÃO ALTERAÇÕES NA COBERTURA VEGETAL

FONTE: A Autora (2015)

4.1 AQUISIÇÃO E PRÉ-PROCESSAMENTO DAS IMAGENS LANDSAT 5 E LANDSAT 8

As imagens utilizadas neste trabalho foram obtidas gratuitamente no site: <http://glovis.usgs.gov/>, pertencente ao U.S. *Geological Survey* dos Estados Unidos (United States Geological Services, U.S.G.S. 1879). A tabela 5 apresenta as características gerais das imagens utilizadas. As datas de aquisição correspondem aos períodos 1990 -1999 e 1999- 2013; na escolha das imagens foi considerado que pertençam aproximadamente à mesma época do ano e que as condições de luminosidade sejam similares. O *datum* de referência é WGS84, elipsóide WGS84, e zona UTM 18 Sul. O ponto e órbita das imagens são 009/060.

TABELA 5 - CARACTERÍSTICAS TÉCNICAS DAS IMAGENS DE SATÉLITE UTILIZADAS NESTE TRABALHO

CARACTERÍSTICAS TÉCNICAS	IMAGENS		
	PERÍODO 1		PERÍODO 2
	1990	1999	2013
ID da Imagem	LT50090601990038CPE04	LT50090601999319CE00	LC80090602013357LGN00
Data da passagem	07/02/1990	15/11/1999	23/12/2013
Tipo de Sensor	L5 - TM	L5 - TM	OLI-TIRS
Nível do processamento	L1T	L1T	L1T
Azimute sol	112.98255620	124.45396311	134.29229543
Elevação do sol	47.57863726	55.95529097	55.30526372
Tempo Central (GTM)	14:41:52	14:55:47	15:21:34

FONTE: A Autora (2015)

4.2 CORREÇÕES DAS IMAGENS

As imagens utilizadas têm correção ao nível L1T (*Standard Terrain Correction*), mas com o fim de minimizar distorções das imagens devido ao espalhamento atmosférico do sinal e dos possíveis erros na geometria, é necessário realizar correções adicionais. O registro das imagens foi realizado com o objetivo de evitar falsas alterações na detecção (Crosta 2002).

Já a correção atmosférica das imagens é realizada usando as ferramentas LEDAPS (*Landsat Ecosystem Disturbance Adaptive Processing System*) geradas e distribuídas gratuitamente pela NASA. (National Aeronautics

and Space Administration, NASA 2011).

As correções da radiância foram feitas de acordo com o trabalho de Chandler e Markham (2003), quando as imagens de diferentes datas são comparadas. É recomendável transformar valores de radiância medidos pelo sensor em valores de reflectância, assim o efeito do ângulo de incidência solar é removido e as diferenças entre os valores de irradiação solar extra-atmosférica são compensadas.

4.3 SELEÇÃO DAS BANDAS

Após da execução das correções, considerando o fato de que no presente trabalho realizar-se a análise de detecção de alterações e que o estudo será focado principalmente na floresta existente na área de investigação, são utilizadas as bandas correspondentes ao vermelho (*R*) e infravermelho próximo (*NIR*) de cada imagem para ambos os períodos considerados (1990-1999) (1999-2013).

De acordo com Gilabert, González, e García (1997), a informação relacionada com a vegetação está contida no índice de vegetação (*IV*), que é um parâmetro calculado a partir dos valores da refletividade em distintos comprimentos de onda. Assim a informação é extraída minimizando a influência das perturbações e condições atmosféricas. O *IV* usa os valores da refletância das zonas espectrais do vermelho e infravermelho próximo, uma vez que a informação espectral da vegetação nestas zonas é ótima.

Entre os índices de vegetação maiormente utilizados encontra-se o Índice de Vegetação de Diferença Normalizada (*NDVI*). O *NDVI* é um índice de vegetação bidimensional sugerido por Rouse, et al. (1974) para produzir um índice espectral que separa a vegetação verde do solo utilizando os níveis digitais. O *NDVI* tem valores na faixa de (-1,0 ; +1,0) onde os valores negativos indicam superfícies sem vegetação como água, neve ou nuvens e os valores positivos ascendentes indicam a vegetação crescente. O sucesso do *NDVI* ao mostrar as variações da vegetação está na normalização realizada, reduzindo o efeito da degradação de calibração do sensor e os efeitos atmosféricos (Gilabert, González y García 1997).

4.4 SEGMENTAÇÃO DAS IMAGENS

O método de segmentação utilizado no presente trabalho é de crescimento de regiões por agregação de pixels (disponível como *oft-seg* no Open Foris) que efetua o processamento com base nos limiares de similaridade e área.

A similaridade referente à proximidade radiométrica entre pixels, está relacionada com o valor da distância euclidiana entre as médias espectrais das regiões. Se a distância calculada é menor do que um limiar predefinido (distância euclidiana mínima), então as duas regiões são consideradas similares e agrupadas. Outro fator que tem que ser definido na segmentação, é o limiar de área, sendo o número mínimo de pixels para que uma região seja individualizada ao tamanho mínimo que cada segmento deve possuir na operação de segmentação (Dlugosz *et al.*, 2005).

O algoritmo de segmentação é controlado por três parâmetros:

1. Tamanho mínimo do segmento em pixels (MinSize)
2. Distância espectral mínima permitida no espaço característico (MinDist)
3. Distância espectral máxima permitida no espaço característico (MaxDist)

Para o presente trabalho, a segmentação foi realizada com os seguintes parâmetros: 50 pixels para o tamanho mínimo, e 0 para a distância mínima, distância máxima e peso.

A verificação visual é realizada para selecionar a segmentação que será utilizada no trabalho; nas figuras 16, 17, 18, 19, 20 e 21 pode-se observar que a segmentação obtida das imagens ajusta-se bem com as classes propostas no capítulo 4 (secção 4.6 Classificação das imagens) para a detecção de alterações para os dois períodos. Uma segmentação inconsistente com os dados das imagens pode gerar erros do classificador RNA, devido à variedade de dados espectrais associados com um único segmento; por conseguinte, a segmentação é uma etapa importante na classificação e detecção de alterações com imagens de satélite.

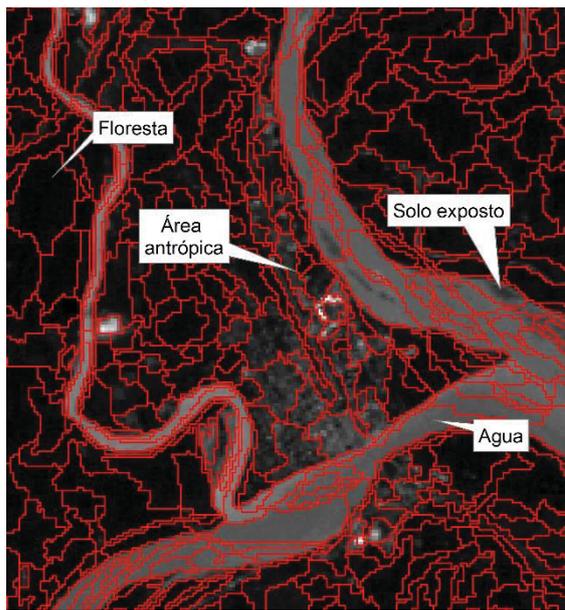


FIGURA 16 - SEGMENTAÇÃO MULTIDATA COM A BANDA DO VERMELHO ANO 1990

FONTE: A Autora (2015)

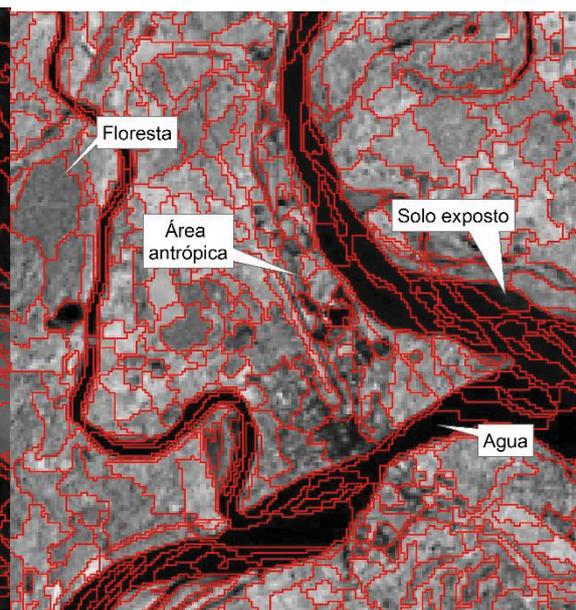


FIGURA 17 - SEGMENTAÇÃO MULTIDATA COM A BANDA DO INFRA-VERMELHO PROXIMO DO ANO 1990

FONTE: A Autora (2015)

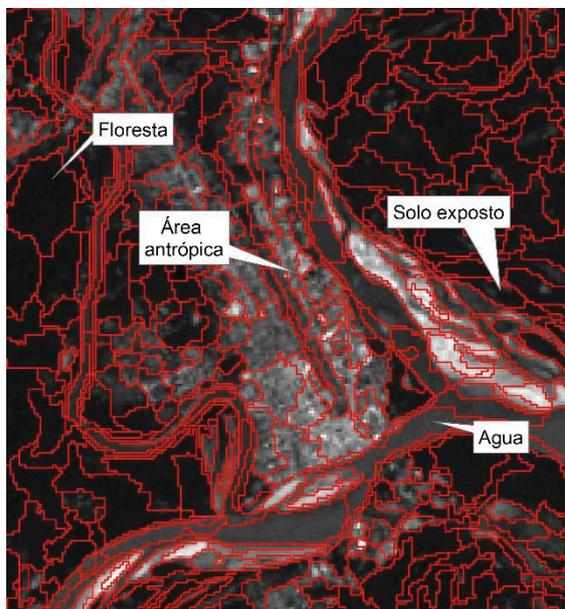


FIGURA 18 - SEGMENTAÇÃO MULTIDATA COM A BANDA DO VERMELHO ANO 1999

FONTE: A Autora (2015)

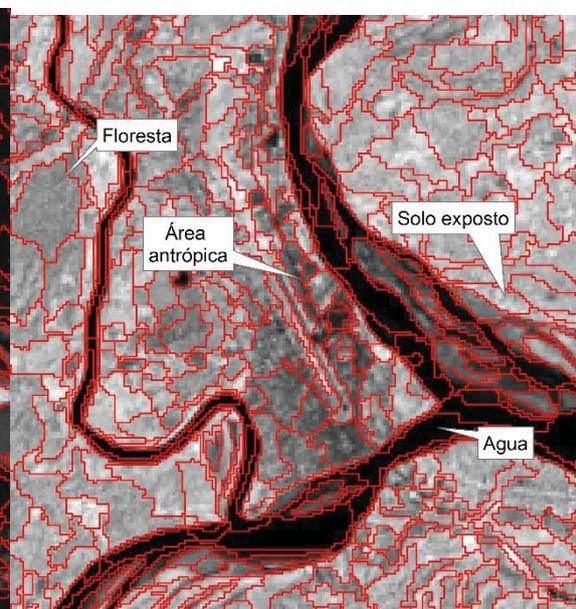


FIGURA 19 - SEGMENTAÇÃO MULTIDATA COM A BANDA DO INFRA-VERMELHO PROXIMO DO ANO 1990

FONTE: A Autora (2015)

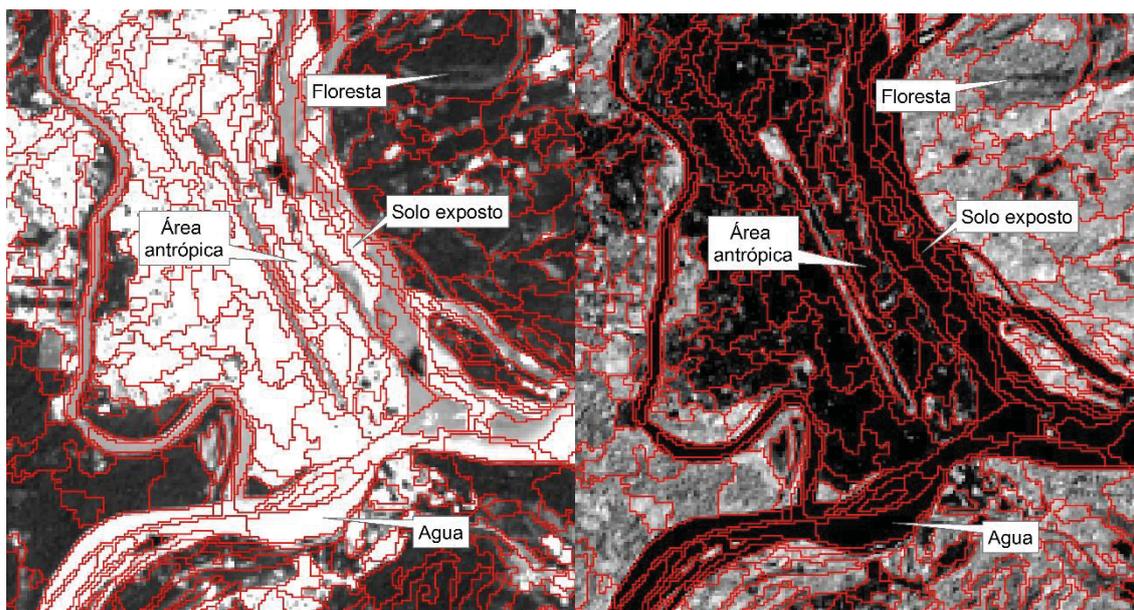


FIGURA 20 - SEGMENTAÇÃO MULTIDATA COM A BANDA DO VERMELHO ANO 2013

FONTE: A Autora (2015)

FIGURA 21 - SEGMENTAÇÃO MULTIDATA COM A BANDA DO INFRA-VERMELHO PROXIMO DO ANO 2013

FONTE: A Autora (2015)

A segmentação multi-data é realizada com as bandas correspondentes ao vermelho (*R*) e infravermelho próximo (*NIR*) de duas imagens da mesma área no período 1 e o período 2. Após a segmentação foram escolhidos visualmente segmentos correspondentes às classes propostas para detecção de alterações e não alterações, e o valor da média dos pixels contidos nesses segmentos são utilizados como dados de entrada da RNA.

4.4.1 Médias dos valores dos segmentos

Foram calculadas as médias dos valores dos pixels contidos nos segmentos, considerando os valores digitais das bandas (4 bandas, 2 por ano) de acordo com a segmentação utilizada.

Com o Open-Foris foram definidos dois períodos para realizar a detecção de alterações na área de estudo. O período 1 corresponde as duas imagens dos anos 1990-1999. O período 2 corresponde as duas imagens dos anos 1999-2013. Nas figuras 22 e 23 apresenta-se os valores calculados das médias dos segmentos gerados para os dois períodos, sendo utilizadas as bandas correspondentes ao vermelho (*R*) e infravermelho próximo (*NIR*) do

espectro.

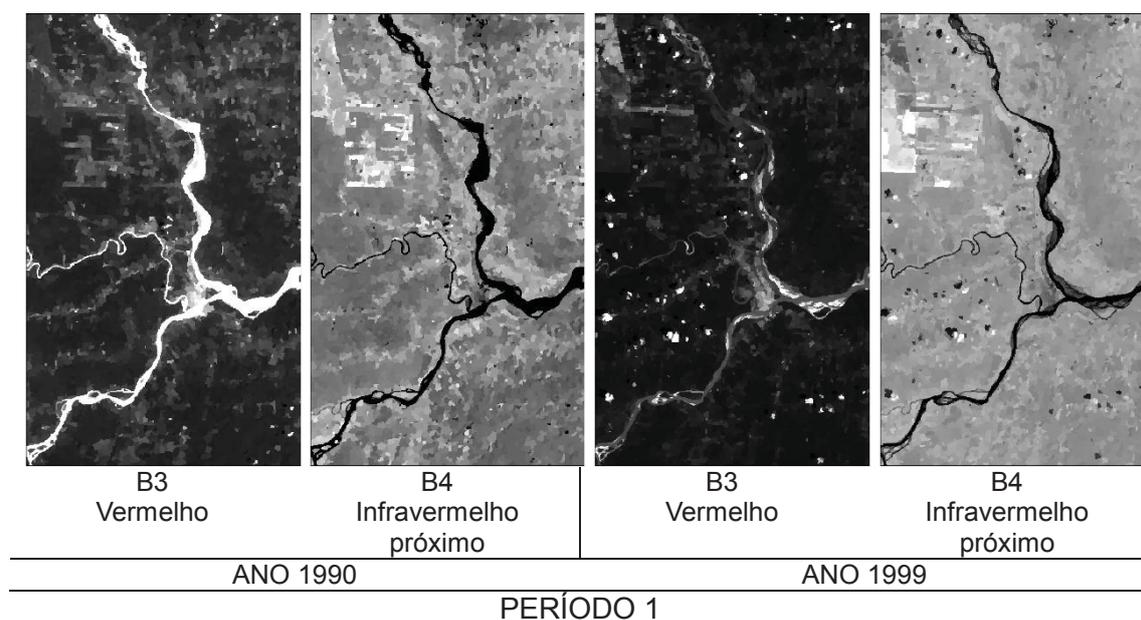


FIGURA 22 - IMAGENS MOSTRANDO OS VALORES DAS MÉDIAS DOS NÍVEIS DIGITAIS DOS PIXELS CONTIDOS EM CADA SEGMENTO

FONTE: A Autora (2015)

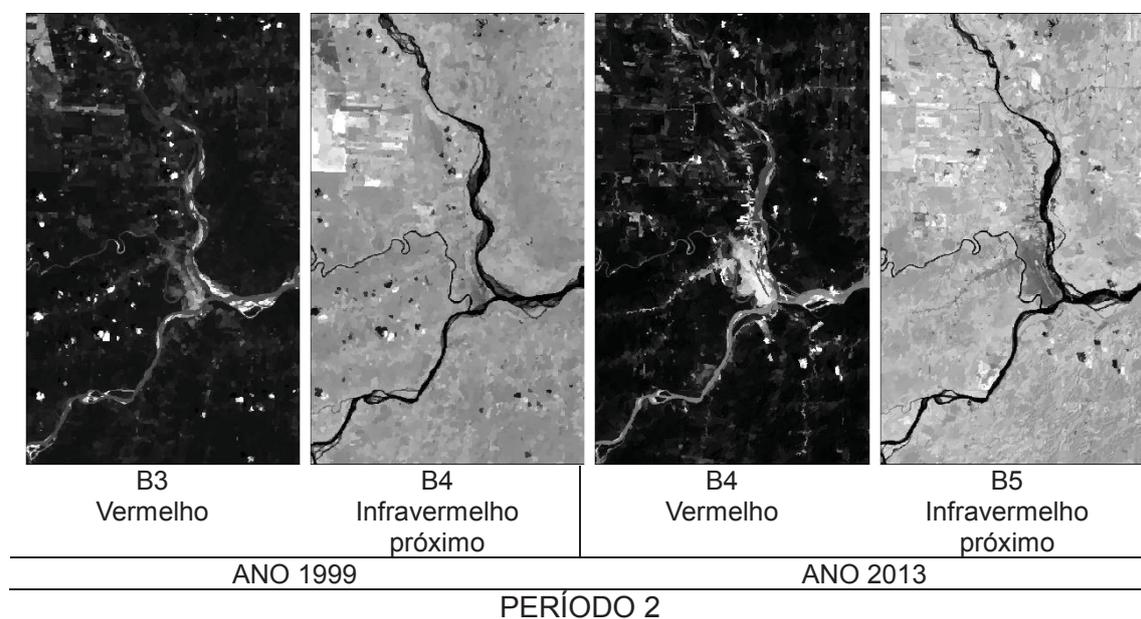


FIGURA 23 - IMAGENS MOSTRANDO OS VALORES DAS MÉDIAS DOS NÍVEIS DIGITAIS DOS PIXELS CONTIDOS EM CADA SEGMENTO

FONTE: A Autora (2015)

Adicionalmente, um arquivo de texto (correspondente ao vetor de

entrada da RNA) com os valores das médias por segmento e por banda é gerado; os dados contidos neste arquivo são utilizados como entrada do treinamento da RNA.

4.5 INTERPRETAÇÃO DA IMAGEM

Segundo Kanade (1981), o método de interpretação de imagem está baseado em três domínios: o domínio da cena que representa o ambiente do mundo real, o domínio da imagem e o domínio dos segmentos que envolvem a representação simplificada do mundo real.

No domínio da cena é feita uma leitura baseada no conhecimento da região de estudo. No domínio da imagem as feições podem ser avaliadas e comparadas com as variações de forma, textura, orientação e tonalidade dos pixels, neste caso as feições não possuem limites rigorosamente determinados, os quais são uma aproximação dos limites reais (A. Antunes 2003).

A interpretação no domínio da imagem é baseada nos princípios da fotointerpretação convencional, onde se consideram os elementos de cor, tonalidade, textura e forma na detecção de diferentes feições. A base do conhecimento adquirida pelo fotointérprete está vinculada ao domínio da imagem (A. Antunes 2003).

O domínio dos segmentos é o apoio à interpretação da imagem. Supondo que exista determinada incerteza na interpretação visual de determinada feição da imagem, o segmento que a representa pode ser discriminatório. O domínio dos segmentos tem importante papel como complemento à interpretação visual da imagem. Apesar dos milhares de objetos com diferentes configurações e orientações que constituem o domínio dos segmentos, o cérebro humano pode ainda reconhecê-los através da percepção visual. Esta percepção organizacional está baseada em 60 estímulos de proximidade, similaridade, simetria e continuidade (Fischler y Firschein 1987).

4.6 CLASSIFICAÇÃO DAS IMAGENS

Realizou-se a classificação supervisionada da área de estudo com o fim de avaliar a detecção de alterações com o método proposto de RNAs. O

classificador de Máxima Verossimilhança (*Maximum Likelihood*) foi selecionado como um método paralelo para comparar os resultados obtidos mediante a RNA. A escolha deste método obedece ao fato de que sua aplicação requer o conhecimento da área analisada, o qual garante que as amostras selecionadas para o treinamento sejam as mais eficientes possíveis e que a classificação resultante represente um padrão de comparação admissível (Crosta 2002).

Para a classificação da imagem com o método MAXVER definiram-se amostras, que são identificadas diretamente na área de estudo sobre a imagem mediante a análise visual e representam as 5 classes propostas (de acordo com a lenda do IPCC):

- 1 Floresta,
- 2 Áreas Agropecuárias,
- 3 Vegetação Arbustiva e Herbácea,
- 4 Corpos de Água,
- 5 Áreas Antrópicas.

Para a análise visual foram utilizadas várias composições coloridas com o fim de destacar as classes propostas por meio do valor espectral, assim para as classes que envolvem a vegetação usaram-se as bandas do vermelho e infravermelho próximo; para o solo exposto e áreas urbanas usara-se a banda do infravermelho médio e para corpos de água usa-se as bandas do azul e do vermelho. Adicionalmente calcula-se o NDVI de cada uma das imagens.

As amostras escolhidas para a classificação foram polígonos nas imagens dos três anos. As figuras 24, 25 e 26 apresentam amostras para a classificação de uma parte da imagem utilizada neste trabalho. As tabelas 6, 7 e 8 mostram os números de polígonos utilizados em cada uma das amostras e o número de pixels contidos nesses polígonos.

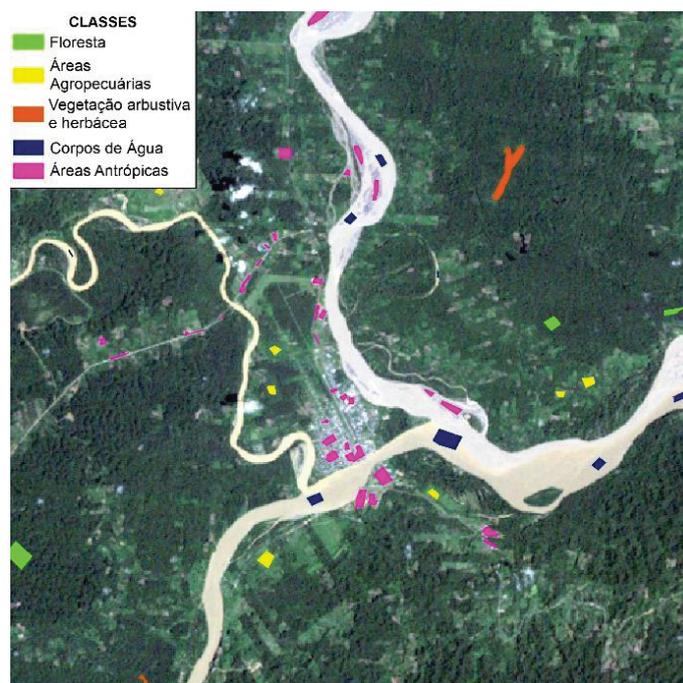


FIGURA 24 - AMOSTRAS PARA A IMAGEM DO ANO 1990

FONTE: A Autora (2015)

TABELA 6 - QUANTIDADE DE POLÍGONOS UTILIZADOS NAS AMOSTRAS DE TREINAMENTO PARA A IMAGEM DO ANO 1990

CLASSE	No. PIXELS	POLÍGONOS
Floresta	1929	12
Áreas Agropecuárias	1552	30
Vegetação arbustiva e herbácea	1140	10
Corpos de Água	903	26
Áreas Antrópicas	1246	35

FONTE: A Autora (2015)

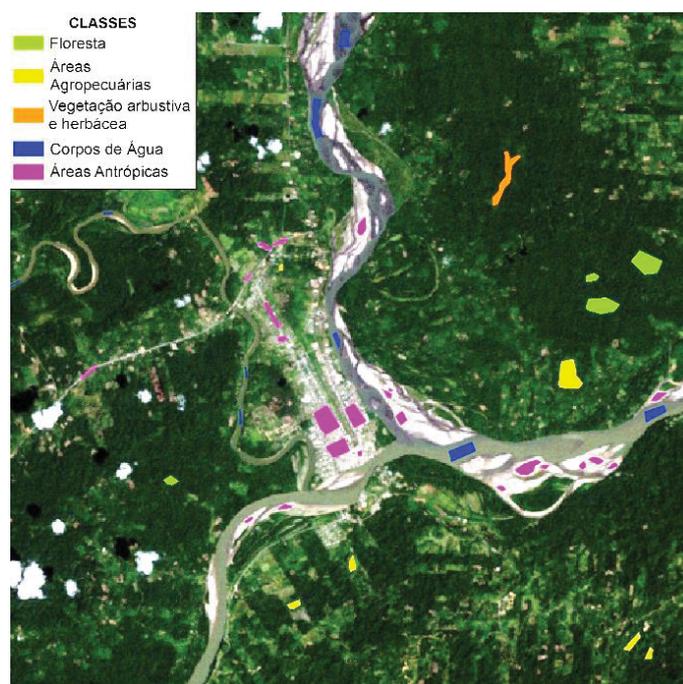


FIGURA 25 - AMOSTRAS PARA A IMAGEM DO ANO 1999

FONTE: A Autora (2015)

TABELA 7 - QUANTIDADE DE POLÍGONOS UTILIZADOS NAS AMOSTRAS DE TREINAMENTO PARA A IMAGEM DO ANO 1999

CLASSE	No. PIXELS	POLÍGONOS
Floresta	2803	14
Áreas Agropecuárias	1607	20
Vegetação arbustiva e herbácea	938	9
Corpos de Água	786	21
Áreas Antrópicas	1007	23

FONTE: A Autora (2015)

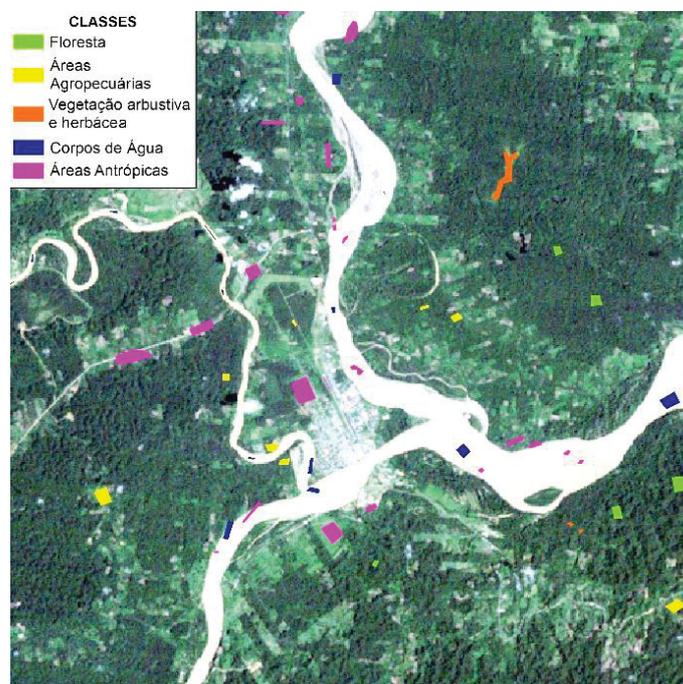


FIGURA 26 - AMOSTRAS PARA A IMAGEM DO ANO 2013

FONTE: A Autora (2015)

TABELA 8 - QUANTIDADE DE POLÍGONOS UTILIZADOS NAS AMOSTRAS DE TREINAMENTO PARA A IMAGEM DO ANO 2013

CLASSE	No. PIXELS	POLÍGONOS
Floresta	1740	20
Áreas Agropecuárias	1704	32
Vegetação arbustiva e herbácea	444	15
Corpos de Água	774	35
Áreas Antrópicas	1167	24

FONTE: A Autora (2015)

4.6.1 Confiabilidade da classificação

Segundo Chuvieco (1990), o produto final da classificação feita de maneira visual ou digital é um mapa temático. Após a classificação de uma

imagem, é preciso conhecer a confiabilidade do produto final, ou seja, avaliar a qualidade. O resultado da classificação está sujeito aos erros posicionais, oriundos da correção geométrica da imagem, mas também a erros temáticos, sendo estes, a categorização equivocada de determinado objeto à determinada classe. A quantificação do erro temático está diretamente associada a processos estatísticos que permitem determinar o grau de concordância entre as classes dos objetos na imagem e as suas classes no terreno. A acurácia e a qualidade das informações representadas na imagem devem ser estimadas, a fim de validar a eficiência do classificador adotado (Antunes, Lingnau y Quintas 2004)

Na literatura é discutido e usados vários métodos de avaliação de acurácia; os mais usados são os baseados na matriz de confusão ou de erros e a sua confiabilidade depende da amostragem dos objetos que devem ser realizadas de maneira randômica (Rosenfield y Lis-Fitzpatrick 1982).

A matriz de confusão serve para observar as discrepâncias entre os dados de campo e a imagem classificada. Em classificação de imagens multiespectrais por métodos convencionais a matriz de confusão é amplamente utilizada (Congalton y Green 2009). Os resultados das matrizes de confusão utilizando o método de RNAs e o método MAXVER estão expostos no capítulo 5.

4.7 AMOSTRAS - DADOS DE TREINAMENTO

Dentro da área escolhida para este trabalho foram selecionados como amostras 4 conjuntos, divididos em 2 conjuntos para informação ao nível de pixel e 2 conjuntos para a informação ao nível de segmentos. As seguintes figuras amostram a distribuição das amostras na área de trabalho. A continuação, as figuras mostradas contêm a distribuição de pontos para os períodos 1 e 2, seja ao nível de segmento ou nível de pixel.

A figura 27 contém as amostras coletadas ao nível de pixels para o período 1 (1990-1999) e para o método da RNA. Com um número total de 502 amostras distribuídas da seguinte forma:

- Treinamento (302)
- Validação (100)
- Teste (100)

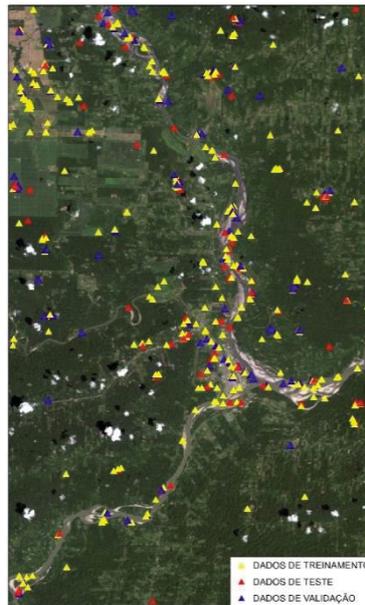


FIGURA 27 - AMOSTRAS PARA TREINAMENTO DA RNA COM PIXELS PERIODO 1
FONTE: A Autora (2015)

A figura 28 contém as amostras coletadas ao nível de pixels para o período 2 (1999-2013) e para o método da RNA. Com um número total de 300 amostras distribuídas da seguinte forma:

- Treinamento (180)
- Validação (60)
- Teste (60)

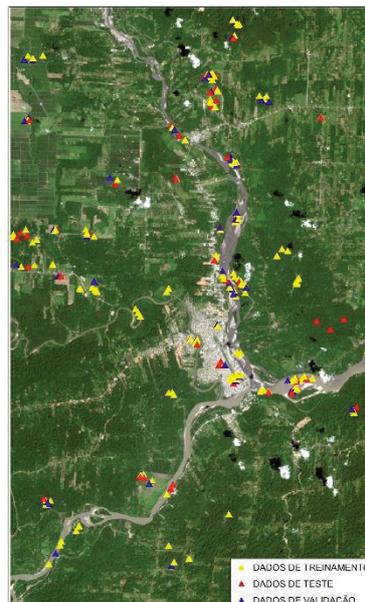


FIGURA 28 - AMOSTRAS PARA TREINAMENTO DA RNA COM PIXELS PERIODO 2
FONTE: A Autora (2015)

A figura 29 contém as amostras coletadas ao nível de segmentos para o período 1 (1990-1999) e para o método de RNA. Com um número total de 165 amostras distribuídas da seguinte forma:

- Treinamento (110)
- Validação (33)
- Teste (22)

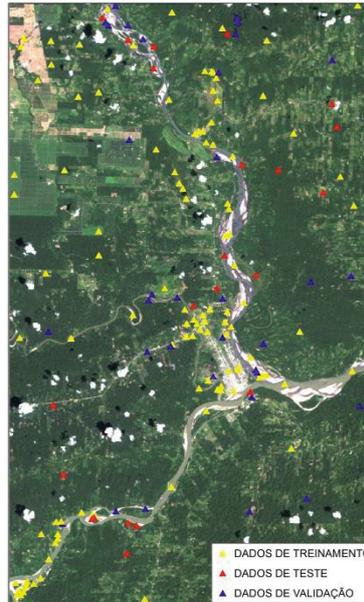


FIGURA 29 - AMOSTRAS PARA TREINAMENTO DA RNA COM SEGEMENTOS PERIODO 1
FONTE: A Autora (2015)

A figura 30 contém as amostras coletadas ao nível de segmentos para o período 2 (1999-2013) e para o método de RNA. Com um número total de 150 amostras distribuídas da seguinte forma:

- Treinamento (100)
- Validação (30)
- Teste (20)

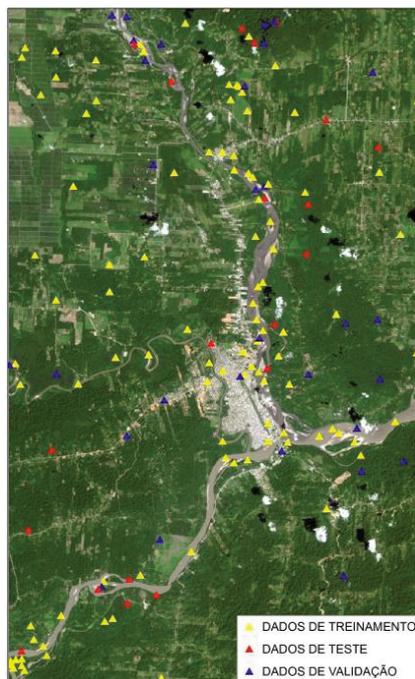


FIGURA 30 - AMOSTRAS PARA TREINAMENTO DA RNA COM SEGMENTOS PERÍODO 2
 FONTE: A Autora (2015)

Estas amostras, que constituem o conjunto de treinamento da RNA, foram distribuídas em três subconjuntos: conjunto de treinamento, conjunto de validação e conjunto de teste.

As alterações consideradas para a região de estudo baseiam-se no estabelecimento de cinco classes de cobertura: floresta, áreas agropecuárias, vegetação arbustiva e herbácea, corpos de água e áreas antrópicas. As alterações na cobertura serão determinadas segundo a tabela 9, sendo que aquelas alterações para as quais não se registra ocorrência na área de estudo serão desconsideradas (n/a = não avaliada).

TABELA 9 - CLASSES PROPOSTAS PARA DETECÇÃO DE ALTERAÇÃO E NÃO ALTERAÇÃO

CLASSES	Floresta	Áreas Agropecuárias	Vegetação arbustiva e herbácea	Corpos de Água	Áreas Antrópicas
Floresta	Sem alteração	Alteração	n/a	n/a	n/a
Áreas Agropecuárias	n/a	Sem alteração	n/a	Alteração	Alteração

Continua

TABELA 9 - CLASSES PROPOSTAS PARA DETECÇÃO DE ALTERAÇÃO E NÃO ALTERAÇÃO

Conclusão

CLASSES	Floresta	Áreas Agropecuárias	Vegetação arbustiva e herbácea	Corpos de Água	Áreas Antrópicas
Vegetação arbustiva e herbácea	n/a	n/a	Sem alteração	n/a	n/a
Corpos de Água	n/a	Alteração	n/a	Sem alteração	n/a
Áreas Antrópicas	n/a	Alteração	n/a	n/a	Sem alteração

FONTE: A Autora (2015)

A tabela 9 mostra as classes utilizadas para detecção de alterações e não alterações no treinamento da RNA, sendo para isto utilizadas as cinco classes propostas inicialmente e que correspondem às não alterações, adicionalmente são definidas outras cinco classes associadas às alterações registradas na área de estudo. Em total 10 classes foram definidas com um número denominado “valor atribuído” e que corresponde à saída da rede. Este número está baseado nos valores de NDVI, ou seja, calcula-se o NDVI para cada imagem, e de acordo com os valores do intervalo que a análise visual mostra para cada classe, atribui-se o número para cada uma, como se expõe na tabela 10.

TABELA 10 - INTERVALOS DE NDVI PARA AS IMAGENS DOS ANOS UTILIZADOS NO ESTUDO

CLASSE	INTERVALO NDVI 1990	INTERVALO NDVI 1999	INTERVALO NDVI 2013
Água	-0,30 / -0,09	-0,37 / -0,10	-0,37 / -0,09
Áreas Antrópicas	-0,06 / 0,45	-0,06 / 0,39	-0,08 / 0,45
Vegetação arbustiva e herbácea	0,50 / 0,58	0,50 / 0,57	0,47 / 0,60
Floresta	0,60 / 0,66	0,59 / 0,66	0,59 / 0,66
Agropecuária	0,67 / 0,71	0,67 / 0,75	0,66 / 0,72

FONTE: A Autora (2015)

Os valores estabelecidos para as saídas da rede conforme na tabela 11

estão no intervalo (1 ; 10), dependendo dos valores de NDVI para as classes propostas (tabela 10) sendo os valores extremos de NDVI as classes correspondentes a água (valor mínimo) e as áreas agropecuárias (valor máximo).

Da tabela 9 são extraídos os tipos de alterações que constituem as saídas esperadas da RNA ou *targets* (tabela 11). As alterações foram relacionadas com um atributo numérico, esta relação é estabelecida considerando que as saídas da RNA são geradas de um processamento matemático.

TABELA 11 - CLASSES ATRIBUÍDAS PARA O TREINAMENTO DA REDE

CLASSE ANO 1	CLASSE ANO 2	SAÍDA DA RNA
Água	Água	1
Água	Agropecuária	2
Áreas Antrópicas	Áreas Antrópicas	3
Áreas Antrópicas	Agropecuária	4
Vegetação arbustiva e herbácea	Vegetação arbustiva e herbácea	5
Floresta	Floresta	6
Floresta	Agropecuária	7
Agropecuária	Água	8
Agropecuária	Áreas Antrópicas	9
Agropecuária	Agropecuária	10

FONTE: A Autora (2015)

O treinamento da RNA é feito com a definição de três subconjuntos de dados: treinamento, validação e teste.

Os dados do subconjunto de treinamento são usados para ajustar os pesos sinápticos mediante o algoritmo de aprendizagem, comparando as saídas geradas pela rede com as saídas desejadas. O cálculo das variações aplicadas aos pesos sinápticos durante a aprendizagem da RNA é realizado com um algoritmo de aprendizagem e em função dos erros gerados para os exemplos do conjunto de treinamento (Basogain 2008).

O subconjunto de validação é usado para controlar um possível sobre-treinamento da rede. Durante o processo de treinamento, os dados de validação

são empregados para controlar o número de iterações realizado na busca da minimização de erros. O processo de treinamento é finalizado quando o erro gerado pela RNA para os exemplos de validação não consegue ser reduzido durante um número predefinido de iterações (Basogain 2008).

O subconjunto de dados de teste, por não estar envolvido no processo de aprendizagem, é usado para fornecer uma estimativa não tendenciosa da capacidade de generalização da rede, os erros gerados por estes dados são livres de vícios (Basogain 2008).

Os anexos 1, 2, 3 e 4 mostram as tabelas dos conjuntos de dados de entrada utilizados no processo de aprendizagem da RNA. Os anexos 3 e 4 mostram as médias dos valores espectrais dos pixels contidos em cada segmento. Já no caso dos anexos 1 e 2, eles mostram os valores espectrais correspondentes ao pixel que contém o ponto de amostragem.

4.8 APRENDIZAGEM DA REDE NEURAL ARTIFICIAL

4.8.1 Treinamento da RNA

Antes do processo de treinamento, é preciso realizar a normalização dos dados de entrada e saída para os conjuntos de treinamento, validação e teste. A normalização é realizada segundo a equação 4.1, com o objetivo de homogeneizar as variáveis usadas no problema, utilizando uma média de zero e um desvio padrão igual a um.

$$y = (x - \bar{x}) \left(\frac{\sigma_y}{\sigma_x} \right) + \bar{y} \quad 4.1$$

Ao aplicar a média igual a zero (0) e desvio padrão igual a um (1) obtemos:

$$y = (x - \bar{x}) \left(\frac{1}{\sigma_x} \right) \quad 4.2$$

Onde:

x = valores sem normalizar

y = valores normalizados

A rede estabelecida no presente trabalho foi de tipo *feedforward*

(propagação para a frente), com 3 camadas interligadas e 10 neurônios na camada oculta (figura 33). Através do processo de tentativa e erro, a arquitetura da rede é definida, a primeira configuração da rede é definida com um valor de neurônios ocultos igual ao número de neurônios na camada de entrada e o seu desempenho é testado aumentando esse número. Finalmente verificou-se o melhor desempenho da rede com 10 neurônios.

O algoritmo de aprendizagem utilizado é o de *Levenberg-Marquardt*. A função de transferência usada na camada oculta é a tangente sigmoide, enquanto que na camada de saída, a função de transferência é de tipo linear. A função de erro a ser minimizada é o Erro Quadrático Médio (RMS).

O processo utilizado para o treinamento de uma RNA envolve um processo de tentativa e erro, isto significa que a arquitetura e parâmetros da rede são modificados até atingir o grau de generalização desejado; cada mudança é registrada no desempenho da rede. O número máximo de iterações é determinado pelo número de épocas estabelecidas e o desempenho da rede ao avaliar dados do conjunto de validação.

O Erro Quadrático Médio (RMS) é calculado para os três subconjuntos. Segundo a rotina de treinamento da RNA implementada, quando durante seis iterações consecutivas não são registradas reduções do RMS calculado para os dados de validação (verificação de validação), o processo iterativo é interrompido, e é necessário então iniciar um novo processo iterativo em caso de não atingir os valores desejados. Os erros gerados pela rede são calculados após cada processo iterativo

O número de camadas da rede, o número de neurônios na camada oculta e o tipo de funções de transferência usada em cada camada irão ser definidas por meio de testes, isso irá estabelecer a arquitetura mais adequada para a RNA. A natureza do problema determina o número de neurônios nas camadas de entrada e de saída, dependendo fundamentalmente do número de variáveis utilizadas para resolver o problema.

A arquitetura da RNA, além do algoritmo de aprendizagem e os parâmetros do treinamento, são implementados dentro de um *script* executado em plataforma Matlab (*The MathWorks Inc.*, 2010) que permite realizar a aprendizagem da RNA (Anexo 13).

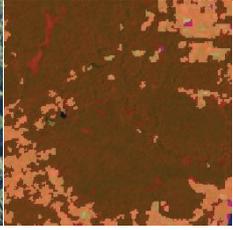
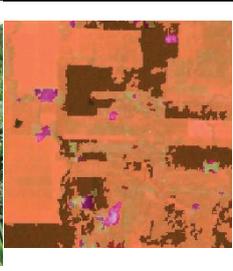
5 RESULTADOS E DISCUSSÕES

5.1 RESULTADOS DA INTERPRETAÇÃO DAS IMAGENS

Para o presente trabalho a visita in loco da região de estudo foi realizada num trabalho prévio executado pelo *Ministerio de Ambiente de Ecuador*. A interpretação visual da imagem foi realizada com base a domínio da cena, das imagens e dos segmentos.

O conhecimento do intérprete sobre o comportamento espectral das classes propostas é essencial para o domínio da imagem. Existem áreas com características espectrais semelhantes, como por exemplo, no caso de áreas urbanas e solo exposto, esta semelhança pode conduzir a confusão na classificação da imagem, devido à proximidade espectral não foi possível discriminar adequadamente estas classes usando apenas a informação oriunda da imagem (características espectrais), portanto, estas duas classes foram combinadas em uma classe chamada de Áreas Antrópicas. Neste trabalho não será abordada o aspecto de forma. A tabela 12 apresenta o resultado da interpretação nos domínios anteriormente descritos:

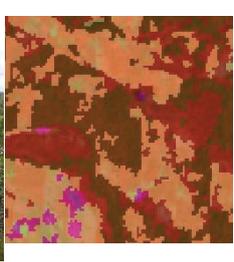
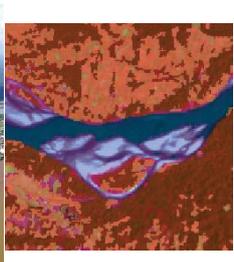
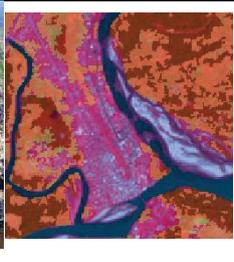
TABELA 12 - RESULTADO DA INTERPRETAÇÃO NOS DOMÍNIOS PROPOSTOS. COMPOSIÇÃO COLORIDA FALSA, BANDAS 4-3-2 (RGB)

Classe	Descrição domínio da imagem	Domínio da cena	Descrição domínio dos segmentos	
Floresta	Alta reflectância na banda do infravermelho. Textura rugosa			Segmentos de tamanhos regulares, pouco fractados
Agropecuária	Alta reflectância nas bandas do visível			Segmentos de forma regular

Continua

TABELA 12 - ESTATÍSTICAS PARA OS DADOS DA RNA DO PERÍODO 1 COM DADOS DE SEGMENTAÇÃO E PIXELS

Conclusão

Classe	Descrição domínio da imagem	Domínio da cena	Descrição domínio dos segmentos	
Vegetação arbustiva e herbácea	Alta reflectância na banda infravermelha. Textura rugosa			Segmentos de forma irregular, assimétricos
Água	Alta reflectância nas bandas do visível pela presença de elementos em suspensão na água			Segmentos de formas assimétricas e tamanhos irregulares
Áreas Antrópicas	Alta reflectância nas bandas do visível			Segmentos de tamanhos irregulares, simétricas y assimétricas

FONTE: ADAPTADO DE (A. Antunes 2003)

5.1.1 Resultados da classificação por Máxima Verossimilhança

Os resultados da classificação por Máxima Verossimilhança foram avaliados mediante a matriz de confusão com amostras das classes utilizadas neste trabalho. Estes resultados são apresentados nas tabelas a seguir:

TABELA 13 - MATRIZ DE CONFUSÃO PARA A CLASSIFICAÇÃO POR MÁXIMA VEROSSIMILHANÇA PARA A IMAGEM DO ANO 1990

Classe	PIXELS					Classe	PORCENTAGEM				
	Floresta	Áreas agropec.	Veget. arbus. e herbác.	Corpos de água	Áreas antróp.		Floresta	Áreas agropec.	Veget. arbus. e herbác.	Corpos de água	Áreas antróp.
Floresta	922	15	74	3	3	Floresta	90,66	1,47	7,28	0,29	0,29
Áreas agropec.	23	544	1	3	3	Áreas agropec.	4,01	94,77	0,17	0,52	0,52
Veget. arbus. e herbác.	10	23	299	0	14	Veget. arbus. e herbác.	2,89	6,65	86,42	0,00	4,05
Corpos de água	17	1	5	537	37	Corpos de água	2,85	0,17	0,84	89,95	6,20
Áreas antróp.	14	6	8	64	628	Áreas antróp.	1,94	0,83	1,11	8,89	87,22

Overall Accuracy 0,90

Kappa Coefficient 0,87

FONTE: A Autora (2015)

TABELA 14 - ERROS DE OMISSÃO E INCLUSÃO PARA A IMAGEM DO ANO 1990 (MAXVER)

Classe	Erros de omissão (Porcentagem)	Erros de comissão (Porcentagem)	Exatidão do ponto de vista do produtor (porcentagem)	Exatidão do ponto de vista do usuário (porcentagem)
Floresta	9,34	6,49	90,66	93,51
Áreas agropec.	5,23	7,64	94,77	92,36
Veget. arbus. e herbác.	13,58	22,74	86,42	77,26
Corpos de água	10,05	11,53	89,95	88,47
Áreas antróp.	12,78	8,32	87,22	91,68

FONTE: A Autora (2015)

TABELA 15 - MATRIZ DE CONFUSÃO PARA A CLASSIFICAÇÃO POR MÁXIMA VEROSSIMILHANÇA PARA A IMAGEM DO ANO 1999

Classe	PIXELS					Classe	PORCENTAGEM				
	Floresta	Áreas agropec.	Veget. arbus. e herbác.	Corpos de água	Áreas antróp.		Floresta	Áreas agropec.	Veget. arbus. e herbác.	Corpos de água	Áreas antróp.
Floresta	1822	279	177	2	0	Floresta	79,91	12,24	7,76	0,09	0,00
Áreas agropec.	27	1182	44	1	34	Áreas agropec.	2,10	91,77	3,42	0,08	2,64
Veget. arbus. e herbác.	80	27	913	4	5	Veget. arbus. e herbác.	7,77	2,62	88,73	0,39	0,49
Corpos de água	0	0	0	860	0	Corpos de água	0,00	0,00	0,00	100,00	0,00
Áreas antróp.	0	64	6	36	857	Áreas antróp.	0,00	6,65	0,62	3,74	88,99

Overall Accuracy 0,91

Kappa Coefficient 0,89

FONTE: A Autora (2015)

TABELA 16 - ERROS DE OMISSÃO E INCLUSÃO PARA A IMAGEM DO ANO 1999 (MAXVER)

Classe	Erros de omissão (Porcentagem)	Erros de comissão (Porcentagem)	Exatidão do ponto de vista do produtor (porcentagem)	Exatidão do ponto de vista do usuário (porcentagem)
Floresta	3,71	14,77	96,29	85,23
Áreas agropec.	13,81	5,47	86,19	94,53
Veget. arbus. e herbác.	11,85	12,10	88,15	87,90
Corpos de água	15,24	0,00	84,76	100,00
Áreas antróp.	2,52	9,39	97,48	90,61

FONTE: A Autora (2015)

TABELA 17 - MATRIZ DE CONFUSÃO PARA A CLASSIFICAÇÃO POR MÁXIMA VEROSSIMILHANÇA PARA A IMAGEM DO ANO 2013

Classe	PIXELS					Classe	PORCENTAGEM				
	Floresta	Áreas agropec.	Veget. arbus. e herbác.	Corpos de água	Áreas antróp.		Floresta	Áreas agropec.	Veget. arbus. e herbác.	Corpos de água	Áreas antróp.
Floresta	605	137	64	0	3	Floresta	74,78	16,93	7,91	0,00	0,37
Áreas agropec.	70	676	14	0	22	Áreas agropec.	8,95	86,45	1,79	0,00	2,81
Veget. arbus. e herbác.	21	35	290	0	0	Veget. arbus. e herbác.	6,07	10,12	83,82	0,00	0,00
Corpos de água	23	62	2	421	89	Corpos de água	3,85	10,39	0,34	70,52	14,91
Áreas antróp.	0	40	0	0	673	Áreas antróp.	0,00	5,61	0,00	0,00	94,39

Overall Accuracy 0,82

Kappa Coefficient 0,77

FONTE: A Autora (2015)

TABELA 18 - ERROS DE OMISSÃO E INCLUSÃO PARA A IMAGEM DO ANO 2013 (MAXVER)

Classe	Erros de omissão (Porcentagem)	Erros de comissão (Porcentagem)	Exatidão do ponto de vista do produtor (porcentagem)	Exatidão do ponto de vista do usuário (porcentagem)
Floresta	25,22	15,86	74,78	84,14
Áreas agropec.	13,55	28,84	86,45	71,16
Veget. arbus. e herbác.	16,18	21,62	83,82	78,38
Corpos de água	29,48	0,00	70,52	100,00
Áreas antróp.	5,61	14,49	94,39	85,51

FONTE: A Autora (2015)

Em imagens de média resolução a classificação por Máxima Verossimilhança produz classes definidas, mas com ruído por utilizar somente

os parâmetros espectrais por causa de ser uma classificação temática da cobertura vegetal. As classes propostas foram corretamente classificadas na maioria das imagens, as porcentagens das matrizes dos erros apresentaram valores maiores que 79% nas diagonais, sendo que a classe com melhores resultados na classificação foi corpos de água.

5.1.2 Resultados do treinamento da Rede Neural Artificial

As tabelas 19 e 20 mostram os resultados para os dados de treinamento, validação e teste utilizando a informação oriunda da segmentação e também aquela a nível de pixel para a Época1 e Época 2 respectivamente.

TABELA 19 - ESTATÍSTICAS PARA OS DADOS DA RNA DO PERÍODO 1 COM DADOS DE SEGMENTAÇÃO E PIXELS

SEGMENTOS		PIXELS	
ERROS PARA OS DADOS DE TREINAMENTO		ERROS PARA OS DADOS DE TREINAMENTO	
Máximo	0,96960750	Máximo	0,00015153
Mínimo	-0,99966399	Mínimo	-0,00015596
ERROS PARA OS DADOS DE VALIDAÇÃO		ERROS PARA OS DADOS DE VALIDAÇÃO	
Máximo	0,77224904	Máximo	0,00764283
Mínimo	-1,57480836	Mínimo	-0,00045555
ERROS PARA OS DADOS DE TESTE		ERROS PARA OS DADOS DE TESTE	
Máximo	1,51998056	Máximo	0,00350044
Mínimo	-1,49517014	Mínimo	-0,03309537

FONTE: A Autora (2015)

Os resultados apresentam diferenças significativas quando comparado o caso de treinamento da RNA utilizando informação obtida dos segmentos e informação ao nível de pixel. Os melhores resultados foram alcançados com a informação ao nível de pixel. Isto pode ser explicado pelo uso de imagens de média resolução onde não é empregada as características de forma; no entanto, para atingir os objetivos do presente trabalho, as características espectrais são suficientes. A Tabela 20, apresenta os valores obtidos do treinamento da RNA para o Período 2 com informação ao nível dos segmentos e de pixel.

TABELA 20 - ESTATÍSTICAS PARA OS DADOS DA RNA DO PERÍODO 2 COM DADOS DE SEGMENTAÇÃO E PIXELS

SEGMENTOS		PIXELS	
ERROS PARA OS DADOS DE TREINAMENTO		ERROS PARA OS DADOS DE TREINAMENTO	
Máximo	3,52925739	Máximo	5,47432767e-06
Mínimo	-2,69492483	Mínimo	-5,29482581e-06
ERROS PARA OS DADOS DE VALIDAÇÃO		ERROS PARA OS DADOS DE VALIDAÇÃO	
Máximo	4,70229917	Máximo	0,00066857
Mínimo	-1,45132180	Mínimo	-1,30878167e-06
ERROS PARA OS DADOS DE TESTE		ERROS PARA OS DADOS DE TESTE	
Máximo	4,44656720	Máximo	0,00891056
Mínimo	-2,42164622	Mínimo	-0,03866069

FONTE: A Autora (2015)

A tabela 21, apresenta o menor RMS obtido para o treinamento da rede, isto significa a iteração do treinamento onde se obtêm os melhores resultados. Observa-se que os menores valores do RMS correspondem aos subconjuntos que utilizam informação ao nível de pixel.

TABELA 21 - ERRO QUADRÁTICO MÉDIO (RMS OBTIDO DURANTE AS ITERAÇÕES PARA OS COJUNTOS DE TREINAMENTO DA REDE

Período	Nível de informação	# Iteração	Treinamento (RMS)	Validação (RMS)	Teste (RMS)	Gradiente
1	Segmentos	11	0,05886172	0,11215975	0,14680737	0,00271850
1	Pixels	92	7,33151802e-11	1,26954984e-05	1,95699544e-06	9,49957630e-08
2	Segmentos	05	0,10293546	0,22215228	0,21713743	0,00952008
2	Pixels	51	1,02864990e-13	9,15338790e-10	3,32703165e-06	1,02864990e-13

FONTE: A Autora (2015)

A figura 31, mostra o resultado dos parâmetros do melhor desempenho de uma rede treinada no software utilizado.

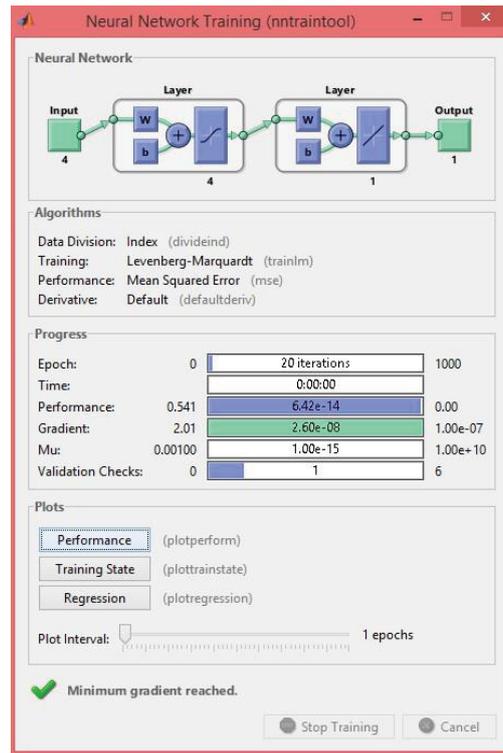


FIGURA 31 - PARÂMETROS DE DESEMPENHO DA REDE
 FONTE: SOFTWARE MATLAB – TREINAMENTO DE UMA RNA

A figura 32 mostra como o RMS diminui à medida que o processo iterativo avança.

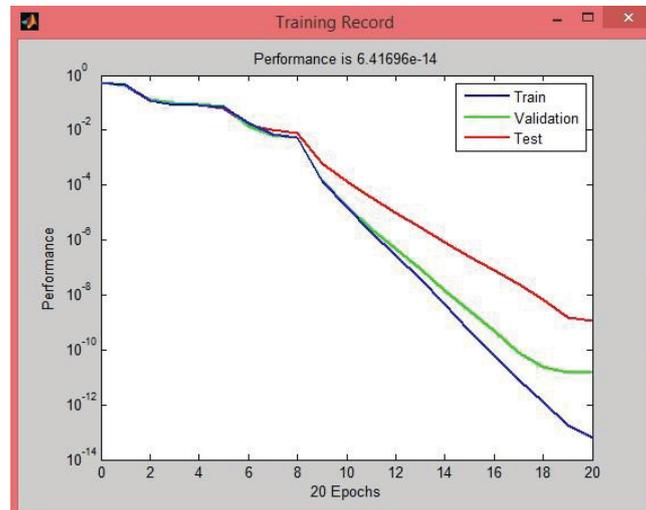


FIGURA 32 - MINIMIZAÇÃO DOS ERROS NOS CONJUNTOS DE TREINAMENTO, VALIDAÇÃO E TESTE DA RNA

FONTE: SOFTWARE MATLAB – TREINAMENTO DE UMA RNA

A figura 33 mostra a arquitetura da rede de tipo *feedforward* que foi

testada e avaliada. A rede tem três camadas interligadas e dez neurônios dentro da camada oculta. O algoritmo de aprendizagem usado foi o de *Levenberg-Marquardt*, explicado anteriormente nos capítulos 3 e 4.

O *script* de treinamento estabelece um número máximo de 1000 iterações, e uma meta igual ao valor zero.

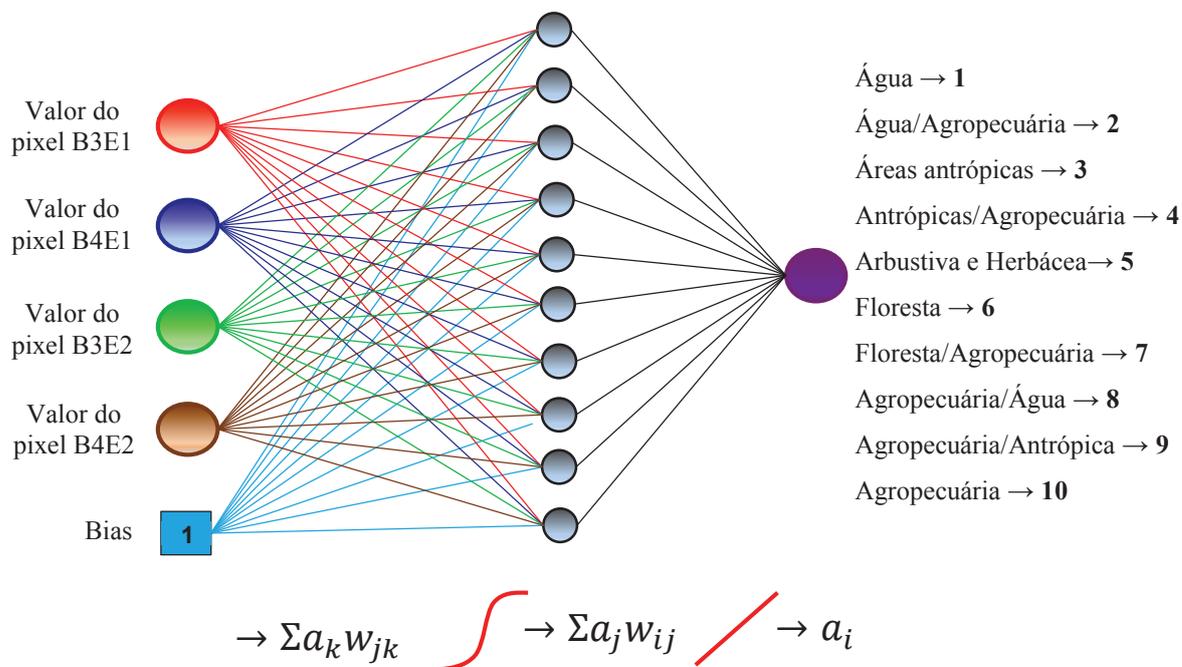


FIGURA 33 - DESENHO DA REDE NEURAL ARTIFICIAL PARA O PRESENTE TRABALHO

FONTE: A Autora (2015)

Nos anexos 5, 6, 9 e 10 são mostrados os pesos sinápticos dos parâmetros da rede estabelecidos logo depois da aprendizagem. Os valores dos *bias* são detalhados nos anexos 7, 8, 11 e 12.

Uma vez realizado o treinamento da RNA; os parâmetros gerados pela rede são armazenados em um arquivo, com novos dados de entrada. A configuração da RNA treinada pode ser usada para prever saídas, e testar o funcionamento e desempenho da rede em termos de sua capacidade de generalização.

Os resultados foram avaliados mediante uma matriz de confusão, eles são expostos nas seguintes tabelas:

TABELA 22 - MATRIZ DE CONFUSÃO PARA A CLASSIFICAÇÃO POR RNA PARA A IMAGEM DO ANO 1990

PIXELS						PORCENTAGEM					
Classe	Floresta	Áreas agropec.	Veget. arbus. e herbác.	Corpos de água	Áreas antróp.	Classe	Floresta	Áreas agropec.	Veget. arbus. e herbác.	Corpos de água	Áreas antróp.
Floresta	990	15	11	0	1	Floresta	97,35	1,47	1,08	0,00	0,10
Áreas agropec.	40	529	1	1	3	Áreas agropec.	6,97	92,16	0,17	0,17	0,52
Veget. arbus. e herbác.	26	0	320	0	0	Veget. arbus. e herbác.	7,51	0,00	92,49	0,00	0,00
Corpos de água	11	0	15	551	20	Corpos de água	1,84	0,00	2,51	92,29	3,35
Áreas antróp.	10	10	24	47	629	Áreas antróp.	1,39	1,39	3,33	6,53	87,36
<i>Overall Accuracy 0,93</i>											
<i>Kappa Coefficient 0,91</i>											

FONTE: A Autora (2015)

TABELA 23 - ERROS DE OMISSÃO E COMISSÃO PARA A IMAGEM DO ANO 1990 (RNA)

Classe	Erros de omissão (Porcentagem)	Erros de comissão (Porcentagem)	Exatidão do ponto de vista do produtor (porcentagem)	Exatidão do ponto de vista do usuário (porcentagem)
Floresta	2,65	8,08	97,35	91,92
Áreas agropec.	7,84	4,51	92,16	95,49
Veget. arbus. e herbác.	7,51	13,75	92,49	86,25
Corpos de água	7,71	8,01	92,29	91,99
Áreas antróp.	12,64	3,68	87,36	96,32

FONTE: A Autora (2015)

TABELA 24 - MATRIZ DE CONFUSÃO PARA A CLASSIFICAÇÃO POR RNA PARA A IMAGEM DO ANO 1999

PIXELS						PORCENTAGEM					
Classe	Floresta	Áreas agropec.	Veget. arbus. e herbác.	Corpos de água	Áreas antróp.	Classe	Floresta	Áreas agropec.	Veget. arbus. e herbác.	Corpos de água	Áreas antróp.
Floresta	1822	279	177	2	0	Floresta	79,91	12,24	7,76	0,09	0,00
Áreas agropec.	27	1182	44	1	34	Áreas agropec.	2,10	91,77	3,42	0,08	2,64
Veget. arbus. e herbác.	80	27	913	4	5	Veget. arbus. e herbác.	7,77	2,62	88,73	0,39	0,49
Corpos de água	0	0	0	860	0	Corpos de água	0,00	0,00	0,00	100,00	0,00
Áreas antróp.	0	64	6	36	857	Áreas antróp.	0,00	6,65	0,62	3,74	88,99
<i>Overall Accuracy 0,88</i>											
<i>Kappa Coefficient 0,84</i>											

FONTE: A Autora (2015)

TABELA 25 - ERROS DE OMISSÃO E COMISSÃO PARA A IMAGEM DO ANO 1999 (RNA)

Classe	Erros de omissão (Porcentagem)	Erros de comissão (Porcentagem)	Exatidão do ponto de vista do produtor (porcentagem)	Exatidão do ponto de vista do usuário (porcentagem)
Floresta	11,87	19,16	88,13	80,84
Áreas agropec.	14,19	3,73	85,81	96,27
Veget. arbus. e herbác.	15,90	32,17	84,10	67,83
Corpos de água	4,86	8,09	95,14	91,91
Áreas antróp.	15,15	2,58	84,85	97,42

FONTE: A Autora (2015)

TABELA 26 - MATRIZ DE CONFUSÃO PARA A CLASSIFICAÇÃO POR RNA PARA A IMAGEM DO ANO 2013

Classe	PIXELS					Classe	PORCENTAGEM				
	Floresta	Áreas agropec.	Veget. arbus. e herbác.	Corpos de água	Áreas antróp.		Floresta	Áreas agropec.	Veget. arbus. e herbác.	Corpos de água	Áreas antróp.
Floresta	718	8	81	0	2	Floresta	88,75	0,99	10,01	0,00	0,25
Áreas agropec.	62	637	5	6	72	Áreas agropec.	7,93	81,46	0,64	0,77	9,21
Veget. arbus. e herbác.	52	0	294	0	0	Veget. arbus. e herbác.	15,03	0,00	84,97	0,00	0,00
Corpos de água	0	23	14	545	15	Corpos de água	0,00	3,85	2,35	91,29	2,51
Áreas antróp.	8	31	115	32	527	Áreas antróp.	1,12	4,35	16,13	4,49	73,91

Overall Accuracy 0,84

Kappa Coefficient 0,80

FONTE: A Autora (2015)

TABELA 27 - ERROS DE OMISSÃO E COMISSÃO PARA A IMAGEM DO ANO 2013 (RNA)

Classe	Erros de omissão (Porcentagem)	Erros de comissão (Porcentagem)	Exatidão do ponto de vista do produtor (porcentagem)	Exatidão do ponto de vista do usuário (porcentagem)
Floresta	11,25	14,52	88,75	85,48
Áreas agropec.	18,54	8,87	81,46	91,13
Veget. arbus. e herbác.	15,03	42,24	84,97	57,76
Corpos de água	8,71	6,52	91,29	93,48
Áreas antróp.	26,09	14,45	73,91	85,55

FONTE: A Autora (2015)

5.1.3 Comparação de resultados

5.1.3.1 Classificação

A tabela 28, apresenta os estatísticos dos métodos de classificação utilizados neste trabalho. O cálculo da acurácia global e do índice *kappa* (Cohen 1960) são usados para estabelecer o desempenho dos métodos usados. A acurácia global foi calculada como a soma da diagonal principal da matriz de confusão dividida pelo total de pixels nas amostras.

TABELA 28 - ACURÁCIA GLOBAL E ÍNDICE KAPPA

Método de classificação	Ano da Imagem	Acurácia Global	Índice Kappa
MAXVER	1990	0,87	0,90
RNA		0,93	0,91
MAXVER	1999	0,91	0,89
RNA		0,88	0,84
MAXVER	2013	0,82	0,77
RNA		0,84	0,80

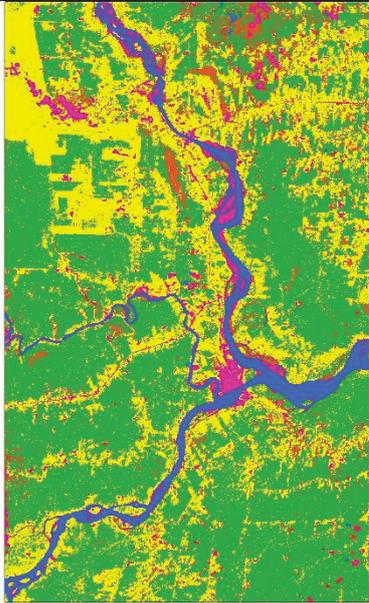
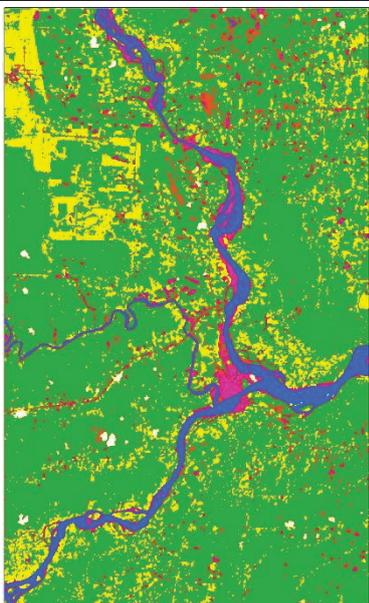
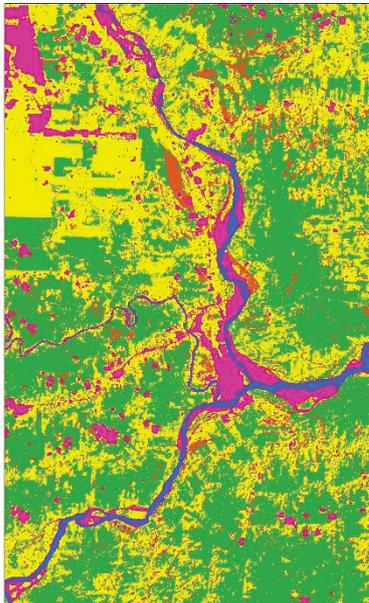
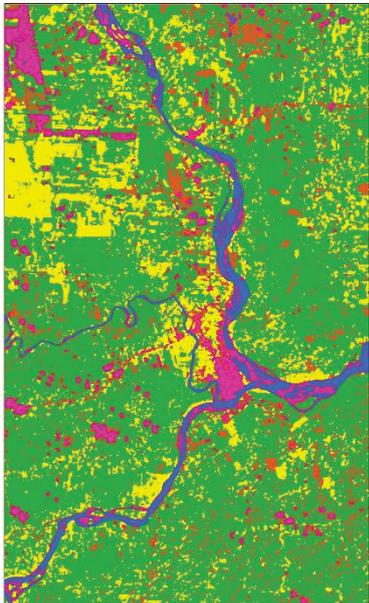
FONTE: A Autora (2015)

Os valores da tabela 28, indicam em geral bom desempenho dos métodos de classificação utilizados. Segundo os valores obtidos para acurácia global e índice *kappa*, a classificação realizada com RNAs tem melhor desempenho para os anos 1990 e 2013. Para o ano 1999 os estatísticos obtidos podem ser interpretados como melhor desempenho do método MAXVER.

O tempo despendido na realização de cada um dos métodos representa fator decisivo. O uso do método MAXVER requer duas classificações prévias e análise posterior para detecção de alterações em um período só; enquanto o método de RNAs resulta mais eficiente na hora de classificar e detectar alterações, devido às entradas na rede permitem obter as saídas que equivalem ao processo de classificação/detecção de alterações em uma etapa. Destaca-se que o conhecimento da área é extremamente importante para a análise independentemente do método utilizado posteriormente.

A Tabela 29, apresenta os resultados das classificações. Observa-se que a classificação por RNA apresenta melhor identificação nas classes, por tanto obtém-se melhor separação das mesmas.

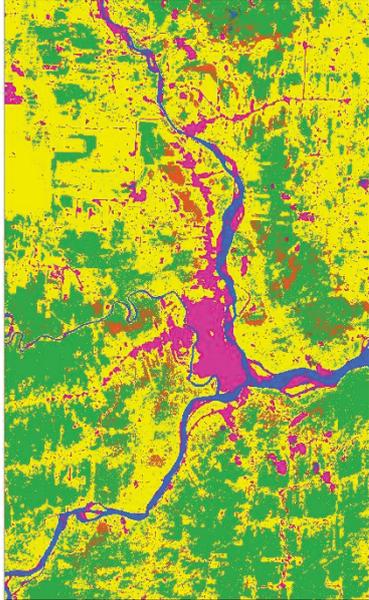
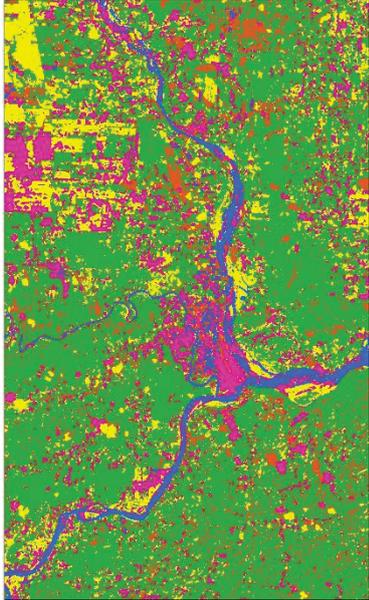
TABELA 29 - COMPARAÇÃO DAS CLASSIFICAÇÕES ENTRE OS MÉTODOS DE RNA E MAXVER

MAXVER		RNA																								
	<table border="1"> <tr> <td></td> <td>Floresta</td> </tr> <tr> <td>53,04%</td> <td>68,08%</td> </tr> <tr> <td></td> <td>Agropec.</td> </tr> <tr> <td>29,56%</td> <td>17,58%</td> </tr> <tr> <td></td> <td>Arb. Herb.</td> </tr> <tr> <td>7,01%</td> <td>4,82%</td> </tr> <tr> <td></td> <td>Água</td> </tr> <tr> <td>4,33%</td> <td>4,07%</td> </tr> <tr> <td></td> <td>Antrópica</td> </tr> <tr> <td>6,06%</td> <td>4,89%</td> </tr> <tr> <td></td> <td>Indeterm.</td> </tr> <tr> <td>s/i</td> <td>0,56%</td> </tr> </table> <p>ANO 1990 As RNA mostram dados não classificados que se correspondem com as nuvens da imagem para o ano 1999.</p>		Floresta	53,04%	68,08%		Agropec.	29,56%	17,58%		Arb. Herb.	7,01%	4,82%		Água	4,33%	4,07%		Antrópica	6,06%	4,89%		Indeterm.	s/i	0,56%	
	Floresta																									
53,04%	68,08%																									
	Agropec.																									
29,56%	17,58%																									
	Arb. Herb.																									
7,01%	4,82%																									
	Água																									
4,33%	4,07%																									
	Antrópica																									
6,06%	4,89%																									
	Indeterm.																									
s/i	0,56%																									
	<table border="1"> <tr> <td></td> <td>Floresta</td> </tr> <tr> <td>44,94%</td> <td>60,67%</td> </tr> <tr> <td></td> <td>Agropec.</td> </tr> <tr> <td>35,61%</td> <td>18,84%</td> </tr> <tr> <td></td> <td>Arb. Herb.</td> </tr> <tr> <td>7,83%</td> <td>10,48%</td> </tr> <tr> <td></td> <td>Água</td> </tr> <tr> <td>1,95%</td> <td>3,20%</td> </tr> <tr> <td></td> <td>Antrópica</td> </tr> <tr> <td>9,67%</td> <td>6,81%</td> </tr> </table> <p>ANO 1999 Pode-se observar que a classificação por MAXVER aumenta consideravelmente as áreas agropecuárias, enquanto as RNA determinam melhor separabilidade entre as classes de floresta e áreas agropecuárias. Também observa-se que as áreas correspondentes aos corpos de água diminuíram notavelmente nas duas classificações. Também é evidente o aumento das áreas antropicas principalmente as regiões correspondentes a áreas urbanas.</p>		Floresta	44,94%	60,67%		Agropec.	35,61%	18,84%		Arb. Herb.	7,83%	10,48%		Água	1,95%	3,20%		Antrópica	9,67%	6,81%					
	Floresta																									
44,94%	60,67%																									
	Agropec.																									
35,61%	18,84%																									
	Arb. Herb.																									
7,83%	10,48%																									
	Água																									
1,95%	3,20%																									
	Antrópica																									
9,67%	6,81%																									

Continua

TABELA 29 - COMPARAÇÃO DAS CLASSIFICAÇÕES ENTRE OS MÉTODOS DE RNA E MAXVER

Conclusão

MAXVER		RNA	
	 Floresta		
	35,05%		52,80%
	 Agropec.		15,38%
	47,14%		10,48%
	 Arb. Herb.		4,23%
	6,01%		2,57%
	 Água		17,11%
	2,57%		9,23%
 Antrópica			
9,23%			
ANO 2013			
Pode-se observar que o aumento das áreas agropecuárias no método MAXVER é muito maior do que o método mostrado pelas RNA; a análise visual da imagem expoe que as áreas agropecuárias aumentaram mas não de maneira muito crítica. Neste caso, o aumento das áreas urbanas com ambos dois métodos pode ser visualizado nas figuras da classificação.			

FONTE: A Autora (2015)

5.1.3.2 Detecção de alterações

Os valores apresentados na tabela 30 mostram os resultados obtidos em área e porcentagem para a detecção de alterações com RNAs nos períodos estudados. Observa-se que as áreas de floresta aumentaram no segundo período, podendo atribuir o fato a um reflorestamento na área, dado coerente com a diminuição das áreas agropecuárias no mesmo segundo período. No entanto, o aumento das áreas antrópicas é evidente, devido ao crescimento das áreas urbanas visíveis nas imagens correspondentes aos períodos comparados, e também a mudança de área agropecuária para solo exposto ou de área agropecuária para área urbana. As áreas chamadas de indeterminadas correspondem aos resultados da análise do primeiro período, e são atribuídas as nuvens presentes na imagem do ano 1999, esta área representa menos de 1% da área total da imagem; já no caso do segundo período as mesmas áreas são atribuídas como mudança de áreas antrópicas para áreas agropecuárias.

TABELA 30 - RESULTADOS DA DETECÇÃO DE ALTERAÇÕES UTILIZANDO O MÉTODO DE RNA

Classe	Estado	PERÍODO 1 (Área Km ²)	Porcentagem (%)	PERÍODO 2 (Área Km ²)	Porcentagem (%)
floresta → floresta	não muda	334,64	45,59	387,55	52,81
áreas agropecuárias → áreas agropecuárias	não muda	67,43	9,19	23,33	3,18
vegetação arbustiva e herbácea → vegetação arbustiva e herbácea	não muda	35,39	4,82	76,94	10,48
água → água	não muda	26,40	3,60	18,83	2,57
áreas antrópicas → áreas antrópicas	não muda	21,00	2,86	22,85	3,11
floresta → áreas agropecuárias	muda	165,02	22,48	57,72	7,86
água → áreas agropecuárias	muda	3,45	0,48	4,66	0,64
áreas antrópicas → áreas agropecuárias	muda	14,87	2,03	27,16	3,70
áreas agropecuárias → água	muda	15,72	2,14	12,21	1,66
áreas agropecuárias → áreas antrópicas	muda	45,91	6,25	102,70	13,99
Indeterminado	-	4,11	0,56	-	-

FONTE: A Autora (2015)

Na tabela 31, observa-se as áreas e porcentagens calculadas para as alterações e não alterações, obtidas depois de uma análise das classificações feitas a partir do método de MAXVER. As áreas da floresta diminuiram no segundo período, em tanto que as áreas agropecuárias têm sido maiores. As áreas antrópicas também apresentam aumento no segundo período devido ao crescimento das áreas urbanas. De igual forma que com o método de RNA, existe mudança de área agropecuária para solo exposto ou de área agropecuária para área urbana. A detecção de alterações com os dois métodos utilizados, apresentam uma diminuição das áreas correspondentes aos corpos de água no segundo os períodos analisados.

TABELA 31 - RESULTADOS DA DETECÇÃO DE ALTERAÇÕES UTILIZANDO O MÉTODO DE MAXVER

Classe	Estado	PERIODO 1 (Área Km ²)	Porcentagem (%)	PERIODO 2 (Área Km ²)	Porcentagem (%)
floresta → floresta	não muda	300,85	40,99	282,87	38,54
áreas agropecuárias → áreas agropecuárias	não muda	191,53	26,09	196,03	26,71
vegetação arbustiva e herbácea → vegetação arbustiva e herbácea	não muda	51,49	7,02	42,33	5,77
água → água	não muda	29,47	4,01	12,90	1,76
áreas antrópicas → áreas antrópicas	não muda	24,49	3,34	38,97	5,31
floresta → áreas agropecuárias	muda	88,41	12,05	98,91	13,48
água → áreas agropecuárias	muda	2,30	0,31	1,40	0,19
áreas antrópicas → áreas agropecuárias	muda	20,01	2,73	32,00	4,36
áreas agropecuárias → água	muda	0,91	0,13	1,58	0,21
áreas agropecuárias → áreas antrópicas	muda	24,49	3,33	26,96	3,67

FONTE: A Autora (2015)

As figuras 34 e 35, mostram mapas de detecção de alterações para os dois períodos utilizando RNA.

ANTES	DEPOIS
	Corpos de Água → Corpos de Água
	Corpos de Água → Áreas Agropecuárias
	Áreas Antrópicas → Áreas Antrópicas
	Áreas Antrópicas → Áreas Agropecuárias
	Vegetação Arbustiva e Herbácea → Vegetação Arbustiva e Herbácea
	Floresta → Floresta
	Floresta → Áreas Agropecuárias
	Áreas Agropecuárias → Água
	Áreas Agropecuárias → Áreas Antrópicas
	Áreas Agropecuárias → Áreas Agropecuárias

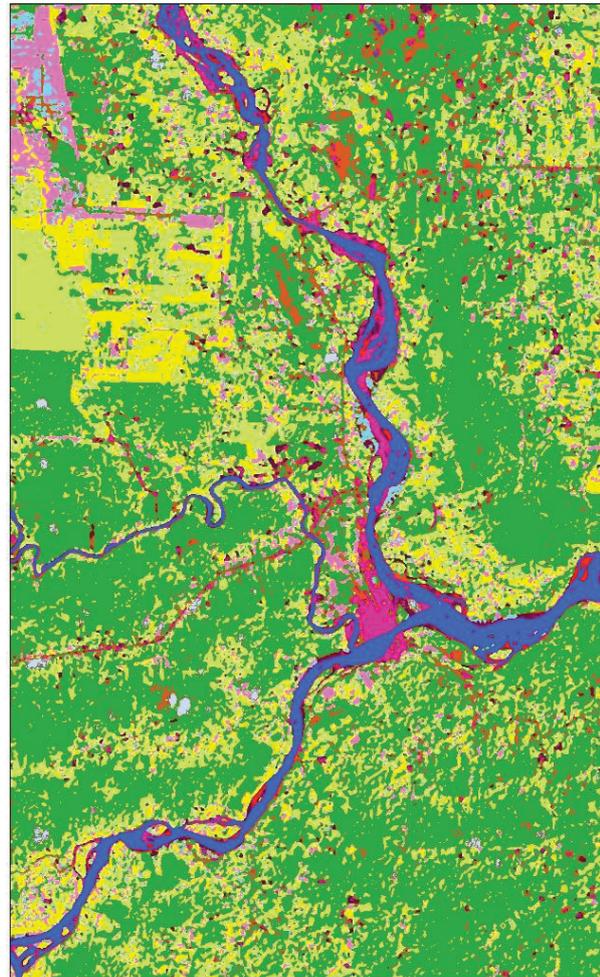


FIGURA 34 - DETECÇÃO DE ALTERAÇÕES NO PERÍODO 1 UTILIZANDO RNA
 FONTE: A Autora (2015)

ANTES	DEPOIS
	Corpos de Água → Corpos de Água
	Corpos de Água → Áreas Agropecuárias
	Áreas Antrópicas → Áreas Antrópicas
	Áreas Antrópicas → Áreas Agropecuárias
	Vegetação Arbustiva e Herbácea → Vegetação Arbustiva e Herbácea
	Floresta → Floresta
	Floresta → Áreas Agropecuárias
	Áreas Agropecuárias → Água
	Áreas Agropecuárias → Áreas Antrópicas
	Áreas Agropecuárias → Áreas Agropecuárias

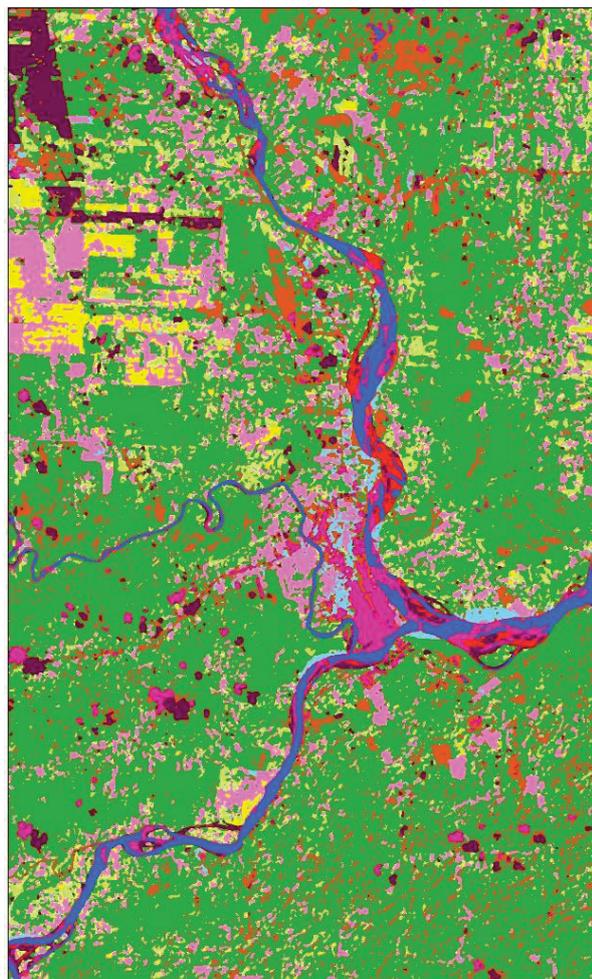


FIGURA 35 - DETECÇÃO DE ALTERAÇÕES NO PERÍODO 2 UTILIZANDO RNA
 FONTE: A Autora (2015)

As figuras 36 e 37, mostram um mapa de detecção de alterações para os dois períodos utilizando MAXVER.

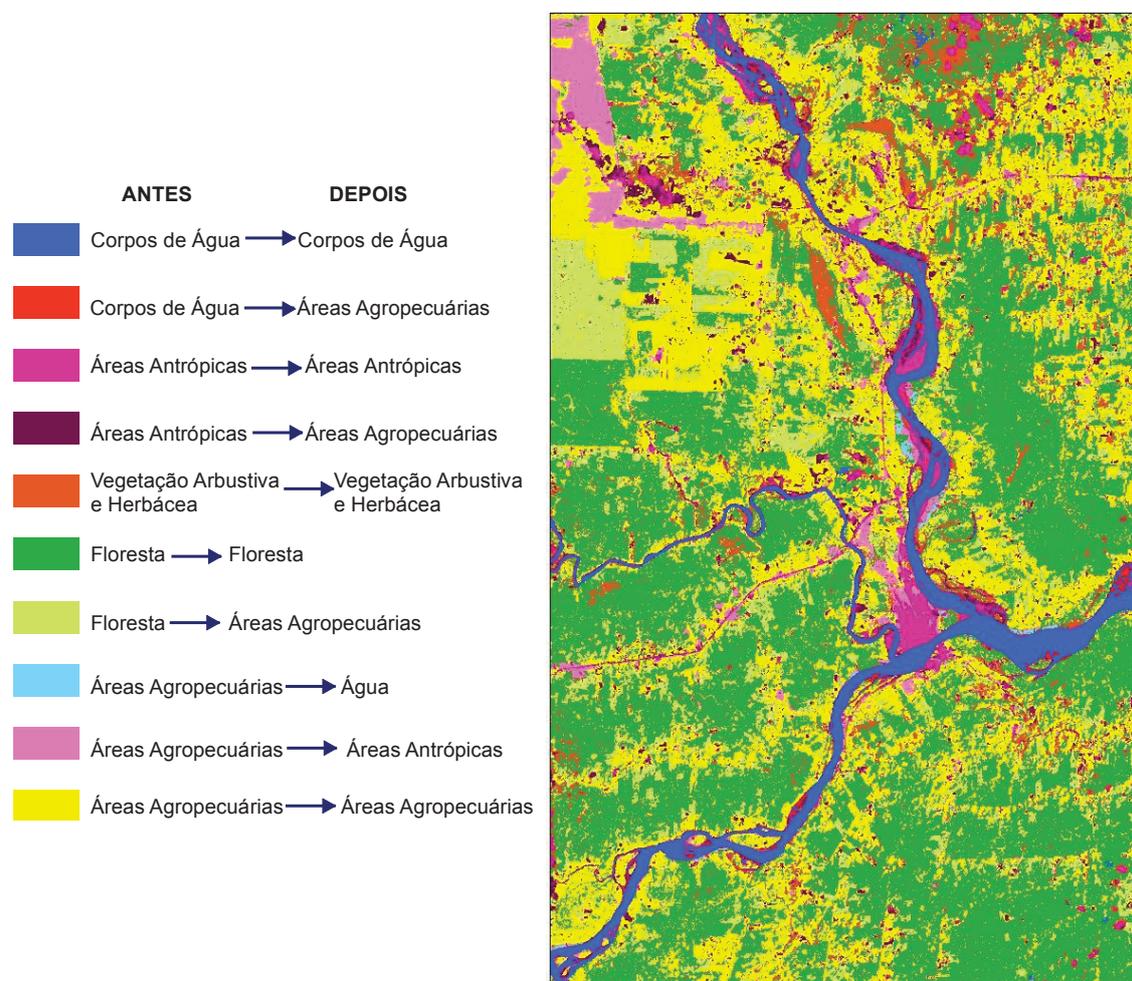


FIGURA 36 - DETECÇÃO DE ALTERAÇÕES NO PERÍODO 1 UTILIZANDO MAXVER

FONTE: A Autora (2015)

ANTES	DEPOIS
Corpos de Água	→ Corpos de Água
Corpos de Água	→ Áreas Agropecuárias
Áreas Antrópicas	→ Áreas Antrópicas
Áreas Antrópicas	→ Áreas Agropecuárias
Vegetação Arbustiva e Herbácea	→ Vegetação Arbustiva e Herbácea
Floresta	→ Floresta
Floresta	→ Áreas Agropecuárias
Áreas Agropecuárias	→ Água
Áreas Agropecuárias	→ Áreas Antrópicas
Áreas Agropecuárias	→ Áreas Agropecuárias

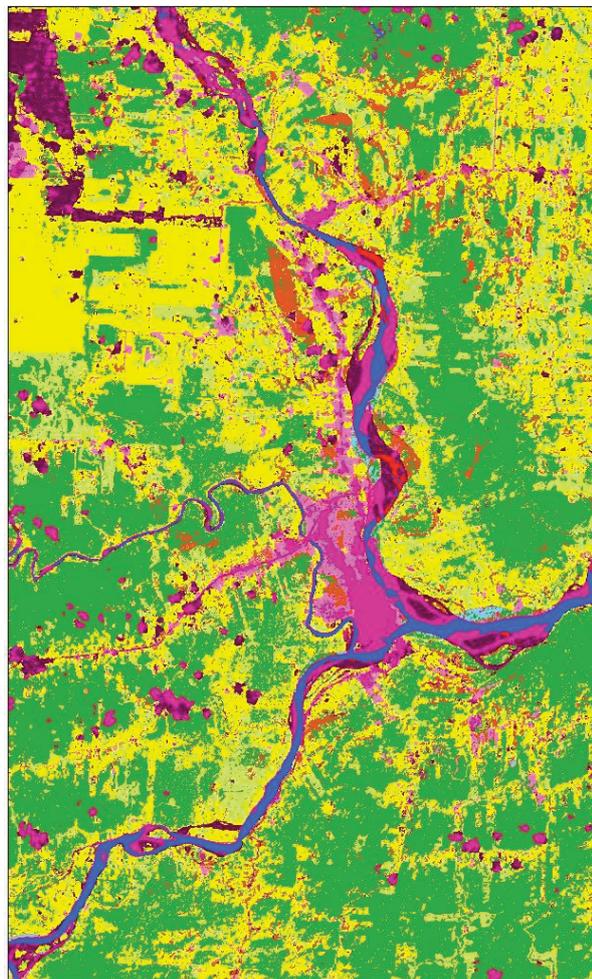


FIGURA 37- DETECÇÃO DE ALTERAÇÕES NO PERÍODO 2 UTILIZANDO MAXVER

FONTE: A Autora (2015)

6 CONCLUSÕES E RECOMENDAÇÕES

6.1 CONCLUSÕES

Com os resultados obtidos neste trabalho, pode-se concluir que:

- O uso da técnica de RNAs para a detecção de alterações mediante imagens de satélite, apresentou melhores resultados do que aqueles obtidos com o método tradicional de Máxima Verossimilhança em termos de acurácia global e o índice *Kappa*. Mesmo quando a definição de parâmetros e treinamento da RNA, em geral requerem tempo de trabalho considerável, o método MAXVER precisa de tratamento pós-classificação, que no caso deste trabalho é maior do que no caso das RNAs. As RNAs, portanto, são opção viável para a classificação de imagens, a fim de detectar alterações na cobertura vegetal.
- As imagens de alta resolução espacial têm algumas vantagens em relação às imagens de resolução média, principalmente quando são requeridas escalas de trabalho maiores. No entanto, o custo de aquisição delas continua elevado. No caso de pesquisas e projetos com apoio financeiro limitado, as imagens do tipo Landsat, Spot, CBERS, etc., são uma opção válida para análises espaciais em escalas médias, a exemplo 1:100.000. A extração de informação ao nível de pixel ainda é suficiente para estas escalas.
- A detecção de alterações proposta neste trabalho permite gerar e atualizar informação de uso da terra quando se dispõe da informação adequada na área de trabalho para os anos do período analisado (análise multi-temporal).
- Não existe uma técnica universalmente ótima ou única para a detecção de alterações. A escolha do método depende do problema apresentado, imagens disponíveis e escala de representação. A metodologia deste trabalho representa uma opção válida para realizar a detecção de alterações através de imagens disponibilizadas de forma gratuita e que reduziria os custos de execução por ser uma metodologia replicável para

outras áreas de estudo e com diferentes épocas de referência.

6.2 RECOMENDAÇÕES

O desempenho da RNA pode ser melhorado em várias formas, citando as seguintes:

- Otimizar o conjunto de dados de treinamento, validação e teste, poderia melhorar significativamente o desempenho das RNAs.
- Sendo que os resultados da classificação de imagens nos métodos supervisionados dependem fundamentalmente da qualidade dos dados de treinamento, é importante que a coleta de amostras em campo seja efetuada por profissionais qualificados.
- O método proposto realiza uma detecção de alterações em função do valor de cinza dos pixels da imagem, no entanto, o uso de índice de vegetação é uma opção conveniente quando a análise principal envolve detecção de alterações na floresta ou outras aplicações como a obtenção de índices tais como o índice de carbono, o índice de desmatamento, quantidade de reflorestamento, etc.
- Pelo fato do conhecimento prévio da área de estudo foi possível realizar a interpretação das imagens, mas é conveniente contar com dados de campo atualizados com o fim de realizar uma verificação para confirmar os resultados obtidos.

REFERENCIAS BIBLIOGRÁFICAS

Ambrosio, G.; González J.; Arévalo V. **MAPIR, Machine Perception and Intelligent Robotics. 2003.** Disponível em: <http://mapir.isa.uma.es/varevalo/drafts/ambrosio2003cis.pdf>. Acesso em: 2014.

Andrade, A.; Centeno J.; Araki H. **Utilização de parâmetros de forma como dado auxiliar na classificação de imagens Ikonos através de redes neurais artificiais.** Simpósio Brasileiro de Geomática, 2002.

Antunes, A.; Lingnau C.; Quintas M. **Análise de acurácia de mapa de uso do solo oriundo de classificação de imagem de alta resolução.** Disponível em: <https://www.ufpe.br/cgtg/ISIMGEO/CD/html/Fotogrametria%20e%20Sensoriamento%20Remoto/Artigos/f005.pdf>. Acesso em: 2004.

Antunes, A. **Classificação de ambiente ciliar baseada em orientação a objeto em imagens de alta resolução espacial.** Programa de Pós-Graduação em Ciências Geodésicas - UFPR. 2003 Disponível em: http://people.ufpr.br/~felipe/tese_final2.pdf. Acesso em: 2014.

Araki, H. **Fusão de informações espectrais, altimétricas e de dados auxiliares na classificação de imagens de alta resolução espacial.** Programa de Pós-Graduação em Ciências Geodésicas - UFPR. 2005. Disponível em: <http://www.cienciasgeodesicas.ufpr.br/>. Acesso em: 2014.

Argote, K.; Reymondin, L.; Jarvis, A. **Detección de cambios en el hábitat usando redes neuronales y datos satelitales MODIS y TRMM en Perú. 2011.** CIAT - International Center for Tropical Agriculture. Disponível em: ftp://ftp.ciat.cgiar.org/DAPA/projects/terra-i/Reportes/pdf/ReporteTerra-i_Per%C3%BA_Sep_2011.pdf. Acesso em: 2015.

Argote, K.; Reymondin, L.; Jarvis, A. **Monitoreo en tiempo real usando redes neuronales y datos MODIS. 2010.** CIAT - International Center for Tropical

Agriculture. Disponível em:
ftp://ftp.ciat.cgiar.org/DAPA/users/acoca/carpeta_areas_protegidas/Areas_Prot egidas_P3/Ftp/Reporte_America_Latina_Espa%C3%B1ol.pdf. Acesso em:
2015.

Barbosa do Nascimento, K.; Parise, M.; Pinheiro, M. **Avaliação de técnicas de classificação de imagens SAR-R99B para o mapeamento do desflorestamento**. Revista Geográfica Acadêmica, 2012. Pp.15-24.

Barreto, J. **Introdução as Redes Neurais Artificiais**. Florianópolis: Departamento de Informática e de Estatística, UFSC, 2002.

Basogain, X. **Redes Neuronales Artificiales y sus Aplicaciones**. Bilbao-España: Departamento de Ingeniería de Sistemas y Automática, Escuela Superior de Ingeniería de Bilbao, 2008.

Berendt, B.; Barkowsky T.; Frecsa, C; Kelter, S. **Spatial Representation with Aspect Maps. Spatial cognition: An interdisciplinary approach to representing and processing spatial knowledge** (Springer), 1998. Pp. 313-336.

Blaschke, T.; Strobl, J. **What's wrong with pixels?** Some recent development interfacing remote sensing and GIS. Pp. 12-17. 2001.

Botelho, M. **Aplicação de Redes Neurais na classificação de imagens de alta resolução e dados do laser scanner usando uma abordagem orientada a regiões**. Programa de Pós-Graduação em Ciências Geodésicas. Fevereiro de 2004. Disponível em:
http://www.cienciasgeodesicas.ufpr.br/teses/2004/2004_mosar.pdf. Acesso em:
2015.

Buendía, E.; Vargas, E.; Leyva, A.; Terrazas, S. **Aplicación de Redes Neuronales Artificiales y técnicas SIG para la predicción de coberturas forestales**. Revista Chapingo. Pp. 7. 2002.

Carrión, J. 2013. **Generación de una malla de ondulaciones geoidales por el método GPS/nivelación y Redes Neuronales Artificiales a partir de datos dispersos**. 2013. Universidad Nacional de La Plata.

Centeno, J.; Botelho, M. **A influência da alternância entre classes e amostras na entrada da rede neural na classificação de imagem digital**. 2003. Pp.12.

Centeno, J.A. **Sensoriamento Remoto e Processos de Imagens Digitais**. Curitiba: UFPR, 2009.

Chandler, G.; Markham, B. **Revised Landsat-5 TM Radiometric Calibration Procedures and Postcalibration Dynamic Ranges**. IEEE TRANSACTIONS ON GEOSCIENCE AND REMOTE SENSING, Noviembre 2003: 2674-2678.

Chuvieco, E. **Fundamentos de Teledetección Espacial**. Madrid: Ediciones Rialp, 1990.

Cohen, J. **A coefficient of agreement of nominal scales**. Educational and psychological measurement, 1960: 37-40.

Congalton, R.; Green, K. **Assessing the Accuracy of Remotely Sensed Data: Principles and Practices**. Boca Raton, FL.: CRC Press, Taylor & Francis Group, 2009.

Crosta, A. **Processamento Digital de Imagens de Sensoriamento Remoto**. Campinas: UNICAMP/Instituto de Geociências, 2002.

Díaz, J. **Introducción a los métodos numéricos para la solución de ecuaciones**. Cádiz: Universidad de Cádiz, 1998.

Dlugosz, F.; Rosot, N.; Doetzer, M.; Malheiros de Oliveira, Y. **Índice para a avaliação de segmentação de imagens**. FLORESTA, 2005: 131-143.

Ecociencia; EcoPar; MAG-SIGAGR; Jatun-Sacha; IGM. **La vegetación de los Andes del Ecuador**. Quito: IGM, 2004.

Food and agriculture organization of the United Nations - FAO. **Global forest land-use change 1990–2005**. 2005. Disponível em: <http://www.fao.org/docrep/017/i3110e/i3110e.pdf>. Acesso em: 2015.

Fischler, M.; Firschein, O. **Intelligence, the eye, the brain and the computer**. Addison-Wesley Publishing Company: Massachusetts, 1987.

Fiszelew, A.; García-Martínez, R. **Generación automática de redes neuronales con ajuste de parámetros basado en algoritmos genéticos**. 2002. Universidad de Buenos Aires - UBA. S/D. Disponível em: <http://laboratorios.fi.uba.ar/lsi/R-ITBA-26-rrnn-ags.pdf>.

Fkirin, M.; Badwai, S.; Mohamed, S. **Change Detection Using Neural Network with Improvement Factor in Satellite Images**. American Journal of Environmental Sciences, 2009: 706-713.

Gentry, A. **Tree species richness of upper Amazonian forests**. Ecology, 1988: 156-159.

Gilabert, M.; González, J.; García, F. **Acerca de los Índices de Vegetación**. 1997: 10.

Gonzalez, R.; Woods, R. **Digital Image Processing**. New Jersey: Prentice Hall, 2002.

Haykin, S. **Neural Networks**. Editado por Segunda Edición. Hamilton: Bookman, 2001.

Hoffmann, P.; Reinhardt, W. **The extraction of GIS features from high resolution using advanced methods based on additional contextual**

information -first experiences. International Archives of Photogrammetry and Remote Sensing Symposium, 2000: 51-58.

Instituto Nacional de Pesquisas Espaciais - INPE. **Mapeando Alterações da Cobertura Vegetal pelo Método Panamazônia: Caso Exemplo do Município de SINOP-MT.** 2010. Disponível em: <http://www.dsr.inpe.br/>. Acesso em: 2015.

Isasi, P; Galván, I. **Redes de Neuronas Artificiales. Un enfoque práctico.** Madrid-España: Pearson Educación S.A., 2004.

Jorgensen, P.; Ulloa, C.; Maldonado, C. **Riqueza de Plantas Vasculares.** Botánica Económica de los Andes Centrales, 2006: 37-50.

Kanade, T. **Region segmentation: Sinal vs Semantic.** In Computer Graphics and Image, 1981: 279-297.

Lu, D.; Mausel, P.; Brondízios, E.; Moran, E. **Change detection techniques.** Int. J. Remote Sensing 25 (2003): 4-17.

Madsen, K.; Nielsen, H.; Tingleff, O. **Methods for non-linear least squares problems.** Technical University of Denmark, 2004.

Martín Del Brío, B.; Sanz, A. **Redes Neuronales y Sistemas Borrosos: Introducción Teórica y Práctica.** Madrid: Ra-Ma, 1997.

Meneses, P.; De Almeida T. **Introdução ao processamento de imagens de sensoriamento remoto.** Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq). 2012. Disponível em: <http://www.cnpq.br/documents/10157/56b578c4-0fd5-4b9f-b82a-e9693e4f69d8> Acesso em: 2015.

Ministerio del Ambiente del Ecuador. **Protocolo metodológico para la generación del Mapa de Deforestación Histórica en el Ecuador continental.**

Socio Bosque. 2010. Tercera Versión. Disponível em: <http://sociobosque.ambiente.gob.ec/files/Folleto%20linea3.pdf>.

Ministerio del Ambiente de Ecuador. **Metodología para la Representación Cartográfica de los Ecosistemas del Ecuador Continental**. 2012. Disponível em: http://www.ambiente.gob.ec/wp-content/uploads/downloads/2012/09/Documento_Metodolog+%C2%A1a_28_05_2012_v2_1.pdf. Acesso em: 2014.

Moreira, A. **Detecção automática de alterações do coberto florestal com imagens de grande e muito grande resolução espacial**. RUN- Repositório Universidade Nova. 2007. Disponível em: <http://run.unl.pt/bitstream/10362/2403/1/TSIG0037.pdf>. Acesso em: 2015.

Morgan, D.; Scofield, C. **Neural Networks and Speech Processing**. Kluwer Academics Publishers, 1991.

Moya, A. **Detección automática de nuevas construcciones a partir de ortofotos**. Universitat de Valencia. 2012. Disponível em: <http://personales.upv.es/almofue/curso02/26092012Tesina.pdf>. Acesso em: 2014.

National Aeronautics and Space Administration, NASA. **Landsat Ecosystem Disturbance Adaptive Processing System - LEDAPS**. 2011. Disponível em: <http://ledapsweb.nascom.nasa.gov/>. Acesso em: 2014.

OPEN-FORIS-FAO. Food and Agriculture Organization of the United Nations. 2009. Disponível em: <http://www.fao.org/forestry/fma/openforis/en/>. Acesso em: 2014.

Ortiz, E. **Contribución a técnicas de segmentación de imágenes**. Universidad Autónoma de Madrid. 2009. Disponível em: <http://arantxa.ii.uam.es/~jms/pfcsteleco/lecturas/20090930ElenaOrtiz.pdf>. Acesso em: 2014.

Pekkarinen, A. **Open Foris: El software libre para luchar contra el cambio climático**. Disponível em: <https://agua.org.mx/open-foris-el-software-libre-para-luchar-contra-el-cambio-climatico/>. Acesso em: 2014.

Richards, J.; Jia, X. **Remote Sensing Digital Image Analysis: an introduction**. Berlin: Springer, 1999.

Rosenfield, G.; Lis-Fitzpatrick, K. **Sampling for thematic map accuracy testing**. Photogrammetric Eng. & Remote Sensing, 1982: 131-137.

Schneider, W.; Steinwendner, J. **Landcover Mapping by Interrelated Segmentation and Classification of Satellite Images**. 1999. Disponível em: https://www.servirglobal.net/Portals/0/Downloads/2015Trainings/Land%20Cover%20Mapping_TrainingManual_UpdateApril%206.pdf. Acesso em: 2015.

Sierra, R. **Propuesta preliminar de un sistema de clasificación de vegetación para el Ecuador Continental**. 1999. (Ed). Ecociencia. Disponível em: http://www.ecociencia.org/archivos/RSierra_PropVegEcuador_1999-120103.pdf. Acesso em: 2014.

Singh, A. **Change detection in the tropical forest environment of northeastern India**. Editado por M.J. Eden and J.T. Parry. Remote Sensing and Tropical Land Management, 1986: pp 237-254.

Triñanes, J.; Torres, J.; Tobar, A; Hernández, C. **Clasificación de imágenes multiespectrales mediante redes neuronales**. Revista de Teledetección - Asociación Española de Teledetección, Pp. 5. 1994.

United States Geological Services, U.S.G.S. Disponível em: <http://glovis.usgs.gov/>. Acesso em: 2013.

Valencia, et all. **High tree alpha-diversity in Amazonian Ecuador**. Biodiversity and Conservation, Pp. 21-28. 1994.

ANEXOS

ANEXO 1. Dados utilizados no treinamento da RNA para a Época 1. Informação ao nível de pixel	114
ANEXO 2. Dados utilizados no treinamento da RNA para a Época 2. Informação ao nível de pixel.....	114
ANEXO 3. Dados utilizados no treinamento da RNA para a Época 1. Informação ao nível de segmentos	115
ANEXO 4. Dados utilizados no treinamento da RNA para a Época 2. Informação ao nível de segmentos	116
ANEXO 5. Pesos sinápticos entre a camada de entrada e a camada oculta para a Época 1. Informação ao nível de pixel	116
ANEXO 6. Pesos sinápticos entre a camada de oculta e a camada de saída para a Época 1. Informação ao nível de pixel	117
ANEXO 7. Bias para a camada oculta da Época 1. Informação ao nível de pixel	117
ANEXO 8. Bias para a camada de saída da Época 1. Informação ao nível de pixel	117
ANEXO 9. Pesos sinápticos entre a camada de entrada e a camada oculta para a Época 2. Informação ao nível de pixel	118
ANEXO 10. Pesos sinápticos entre a camada de oculta e a camada de saída para a Época 2. Informação ao nível de pixel	118
ANEXO 11. Bias para a camada oculta da Época 2. Informação ao nível de pixel	118
ANEXO 12. Bias para a camada de saída da Época 2. Informação ao nível de pixel	118
ANEXO 13. <i>Script</i> executado em plataforma Matlab	119

Anexo 1: Dados utilizados no treinamento da RNA para a Época 1 (Informação ao nível de pixel). Apenas são mostrados 10 pontos para cada subconjunto.

No.	Tipo de dado	1990_R	1990_NIR	1999_R	1999_NIR	Saída da rede	Classe
001	treinamento	45	35	25	17	1	água
002	treinamento	46	33	19	110	2	água/agropecuária
003	treinamento	31	65	34	75	3	antrópica
004	treinamento	35	48	21	109	4	antrópica/agropecuária
005	treinamento	20	61	23	77	5	veg. arbs. herb.
006	treinamento	17	74	19	87	6	floresta
007	treinamento	17	70	25	133	7	floresta/agropecuária
008	treinamento	17	86	24	16	8	agropecuária/água
009	treinamento	18	89	35	78	9	agropecuária/antrópica
010	treinamento	19	106	19	110	10	agropecuária
001	teste	45	35	28	14	1	água
002	teste	42	34	20	105	2	água/agropecuária
003	teste	32	68	40	55	3	antrópica
004	teste	32	46	18	110	4	antrópica/agropecuária
005	teste	21	67	24	77	5	veg. arbs. herb.
006	teste	15	61	18	77	6	floresta
007	teste	17	72	21	120	7	floresta/agropecuária
008	teste	18	100	23	19	8	agropecuária/água
009	teste	19	96	54	49	9	agropecuária/antrópica
100	teste	17	97	19	100	10	agropecuária
001	avaliação	50	29	29	20	1	água
002	avaliação	46	35	20	126	2	água/agropecuária
003	avaliação	29	75	41	75	3	antrópica
004	avaliação	41	53	21	116	4	antrópica/agropecuária
005	avaliação	20	66	22	71	5	veg. arbs. herb.
006	avaliação	18	72	19	91	6	floresta
007	avaliação	17	73	17	99	7	floresta/agropecuária
008	avaliação	18	91	27	15	8	agropecuária/água
009	avaliação	20	102	37	74	9	agropecuária/antrópica
100	avaliação	18	89	19	127	10	agropecuária

R = Red; NIR = Near-Infrared

Anexo 2: Dados utilizados no treinamento da RNA para a Época 2 (Informação ao nível de pixel). Apenas são mostrados 10 pontos para cada subconjunto.

No.	Tipo de dado	1999_R	1999_NIR	2013_BR	2013_NIR	Saída da rede	Classe
001	treinamento	27	12	7584	6275	1	água
002	treinamento	26	14	6577	21969	2	água/agropecuária
003	treinamento	53	77	11597	12955	3	antrópica
004	treinamento	47	64	6938	22660	4	antrópica/agropecuária
005	treinamento	22	70	6782	16352	5	veg. arbs. herb.
006	treinamento	19	95	6713	20571	6	floresta
007	treinamento	19	87	6816	24467	7	floresta/agropecuária
008	treinamento	19	110	7548	6361	8	agropecuária/água
009	treinamento	20	142	9108	14264	9	agropecuária/antrópica
180	treinamento	21	131	6743	23346	10	agropecuária
001	teste	27	14	7725	6248	1	água
002	teste	25	15	6629	22550	2	água/agropecuária
003	teste	60	66	10625	12005	3	antrópica
004	teste	54	64	6682	22062	4	antrópica/agropecuária

005	teste	27	85	6886	16349	5	veg. arbs. herb.
006	teste	20	85	6673	20020	6	floresta
007	teste	19	87	6862	22968	7	floresta/agropecuária
008	teste	19	108	7779	6331	8	agropecuária/água
009	teste	22	153	9223	14346	9	agropecuária/antrópica
060	teste	21	128	6754	24017	10	agropecuária
001	avaliação	27	14	7682	6257	1	água
002	avaliação	27	16	6663	23304	2	água/agropecuária
003	avaliação	35	77	9817	14837	3	antrópica
004	avaliação	43	67	6725	22880	4	antrópica/agropecuária
005	avaliação	21	72	6691	15734	5	veg. arbs. herb.
006	avaliação	18	90	6630	19756	6	floresta
007	avaliação	18	91	6843	23589	7	floresta/agropecuária
008	avaliação	19	111	7721	6317	8	agropecuária/água
009	avaliação	22	153	8059	15837	9	agropecuária/antrópica
060	avaliação	21	124	6942	24439	10	agropecuária

R = Red; NIR = Near-Infrared

Anexo 3: Dados utilizados no treinamento da RNA para a Época 1 (Informação ao nível de segmentos). Apenas são mostrados 10 pontos para cada subconjunto.

No.	Tipo de dado	Médias dos valores digitais da segmentação 1990_R	Médias dos valores digitais da segmentação 1990_NIR	Médias dos valores digitais da segmentação 1999_R	Médias dos valores digitais da segmentação 1999_NIR	Saída da rede	Classe
001	treinamento	45,12	36,29	26,68	20,38	1	água
002	treinamento	38,24	39,28	20,64	100,27	2	água/agropecuária
003	treinamento	37,83	36,05	42,15	49,47	3	antrópica
004	treinamento	33,77	56,62	22,54	92,77	4	antrópica/agropecuária
005	treinamento	21,74	77,73	24,68	91,98	5	veg. arbs. herb.
006	treinamento	17,24	74,96	19,28	94,49	6	floresta
007	treinamento	18,50	82,33	25,75	118,67	7	bosque/agro
008	treinamento	18,74	80,78	25,56	17,07	8	agropecuária/água
009	treinamento	19,93	84,11	31,55	86,86	9	agropecuária/antrópica
100	treinamento	19,11	100,58	22,32	153,29	10	agropecuária
001	teste	15,95	36,27	16,00	43,36	1	água
002	teste	42,14	34,20	24,04	90,41	2	água/agropecuária
003	teste	34,81	43,62	56,54	51,58	3	antrópica
004	teste	36,56	44,36	21,93	97,34	4	antrópica/agropecuária
005	teste	18,28	71,41	21,87	80,33	5	veg. arbs. herb.
006	teste	17,31	75,65	18,64	91,84	6	floresta
007	teste	17,74	88,49	20,23	111,03	7	bosque/agro
008	teste	20,63	91,19	30,40	26,35	8	agropecuária/água
009	teste	20,01	85,94	31,63	91,04	9	agropecuária/antrópica
020	teste	19,33	88,33	24,05	103,14	10	agropecuária
001	avaliação	40,46	29,20	30,01	14,81	1	água
002	avaliação	41,97	29,04	22,99	94,43	2	água/agropecuária
003	avaliação	29,30	57,38	29,45	31,72	3	antrópica
004	avaliação	35,31	57,88	19,93	102,61	4	antrópica/agropecuária
005	avaliação	18,98	70,53	20,73	84,58	5	veg. arbs. herb.
006	avaliação	17,17	73,42	18,90	86,66	6	floresta
007	avaliação	16,72	73,41	23,67	104,60	7	bosque/agro
008	avaliação	19,57	73,00	29,65	15,67	8	agropecuária/água
009	avaliação	18,91	89,91	38,18	83,23	9	agropecuária/antrópica
030	avaliação	20,57	119,93	23,25	129,99	10	agropecuária

R = Red; NIR = Near-Infrared

Anexo 4: Dados utilizados no treinamento da RNA para a Época 2 (Informação ao nível de segmentos). Apenas são mostrados 10 pontos para cada subconjunto.

No.	Tipo de dado	Médias dos valores digitais da segmentação 1999_R	Médias dos valores digitais da segmentação 1999_NIR	Médias dos valores digitais da segmentação 2013_R	Médias dos valores digitais da segmentação 2013_NIR	Saída da rede	Classe
001	treinamento	26,68	20,38	7796,89	6673,91	1	água
002	treinamento	26,23	16,47	7009,18	17764,20	2	água/agropecuária
003	treinamento	34,77	80,28	10355,20	13260,70	3	antrópica
004	treinamento	42,44	62,33	7351,76	17946,60	4	antrópica/agropecuária
005	treinamento	24,68	91,98	7071,35	17801,70	5	veg. arbs. herb.
006	treinamento	19,28	94,49	6589,36	17707,10	6	floresta
007	treinamento	19,22	95,89	6883,01	25576,20	7	floresta/agropecuária
008	treinamento	22,10	90,66	7744,16	6744,14	8	agropecuária/água
009	treinamento	29,34	89,48	11181,30	15505,60	9	agropecuária/antrópica
010	treinamento	22,97	103,34	6703,46	20082,50	10	agropecuária
100	treinamento	22,32	153,29	7859,53	21236,50	10	agropecuária
001	teste	16,00	43,36	6657,30	12122,80	1	água
002	teste	26,93	16,37	6663,90	20497,20	2	água/agropecuária
003	teste	30,92	82,22	8432,92	15090,90	3	antrópica
004	teste	54,23	49,89	6757,71	20594,70	4	antrópica/agropecuária
005	teste	18,93	85,50	6517,07	16497,00	5	veg. arbs. herb.
006	teste	18,73	90,80	6580,83	18622,50	6	floresta
007	teste	19,05	91,37	8049,85	17093,90	7	floresta/agropecuária
008	teste	19,37	100,33	7797,52	6981,13	8	agropecuária/água
009	teste	19,94	107,10	8473,04	16811,50	9	agropecuária/antrópica
020	teste	19,28	106,20	6627,76	20793,50	10	agropecuária
001	avaliação	17,01	42,96	6517,10	10789,10	1	água
002	avaliação	27,16	23,70	7190,32	17808,00	2	água/agropecuária
003	avaliação	53,44	55,92	9883,79	10937,80	3	antrópica
004	avaliação	65,42	64,86	6666,21	21429,80	4	antrópica/agropecuária
005	avaliação	18,77	85,42	6590,93	17011,20	5	veg. arbs. herb.
006	avaliação	18,90	86,66	6609,79	17067,30	6	floresta
007	avaliação	18,34	91,74	6917,74	22801,40	7	floresta/agropecuária
008	avaliação	21,30	91,04	8828,75	6907,79	8	agropecuária/água
009	avaliação	23,90	86,02	9727,12	13821,20	9	agropecuária/antrópica
030	avaliação	23,25	129,99	6723,14	19395,00	10	agropecuária

R = Red; NIR = Near-Infrared

Anexo 5. Pesos sinápticos entre a camada de entrada e a camada oculta para a Época 1 (Informação ao nível de pixel).

		NEURÔNIOS DA CAMADA DE ENTRADA			
		1	2	3	4
NEURÔNIOS DA CAMADA OCULTA	1	5,530381798	2,593735547	-3,544514327	-2,662557146
	2	-28,26507367	21,7843339	-2,781599769	-3,148967836
	3	-2,977164636	-1,830588404	12,71704159	-27,02029158
	4	-2,86684678	-1,708166897	13,84414988	-27,53064949

5	-47,00009998	31,84485732	3,144168641	0,773893195
6	3,420947137	-4,213223233	-4,904031554	28,40971436
7	-59,22811201	44,7223796	-13,26186473	15,88319446
8	-0,695101724	-0,352315013	-2,618470278	0,954137211
9	-1,370711424	-1,045448798	-6,532179073	-2,61408603
10	15,30233103	-43,84891619	-2,774163753	0,124309273

Anexo 6. Pesos sinápticos entre a camada de oculta e a camada de saída para a Época 1 (Informação ao nível de pixel).

		NEURÔNIOS DA CAMADA OCULTA									
		1	2	3	4	5	6	7	8	9	10
NEURÔNIO DA CAMADA DE SAÍDA	1	-1,260854567	3,47E-01	2,11E+00	-2,287057203	0,52055138	1,74E-01	0,17352174	7,62E-06	-5,89E-06	-0,34703401

Anexo 7. Bias para a camada oculta da Época 1 (Informação ao nível de pixel).

BIAS PARA A CAMADA OCULTA		
NEURÔNIOS DA CAMADA OCULTA	1	15,5716
	2	-3,58593214
	3	21,5357319
	4	22,6704826
	5	-55,3249043
	6	45,0320592
	7	-41,8133411
	8	0,35874397
	9	-4,73952005
	10	-72,3064437

Anexo 8. Bias para a camada de saída da Época 1 (Informação ao nível de pixel).

BIAS PARA A CAMADA DE SAÍDA		
NEURÔNIO DA CAMADA DE SAÍDA	1	1,079287956

Anexo 9. Pesos sinápticos entre a camada de entrada e a camada oculta para a Época 2 (Informação ao nível de pixel).

		NEURÔNIOS DA CAMADA DE ENTRADA			
		1	2	3	4
NEURÔNIOS DA CAMADA OCULTA	1	0,359915683	-0,141312208	-0,009434387	0,090557297
	2	6,752004968	-6,178535222	-0,459432285	-0,371656573
	3	1,407667001	0,47884682	-1,320661764	0,555648743
	4	28,39805035	-19,48237612	-5,883790465	-23,49485846
	5	-28,01003183	27,71507254	11,43294365	1,1216596
	6	0,000296112	1,795909723	-3,167662845	1,150007838
	7	-22,45008814	0,609165361	18,11129124	-42,6823922
	8	21,84812709	-19,26449432	-1,319397502	-1,402484889
	9	77,42193531	-60,11304401	-45,28187101	-7,749840559
	10	0,098604277	22,28774863	18,32213259	5,539296781

Anexo 10. Pesos sinápticos entre a camada de oculta e a camada de saída para a Época 2 (Informação ao nível de pixel).

		NEURÔNIOS DA CAMADA OCULTA									
		1	2	3	4	5	6	7	8	9	10
NEURÔNIO DA CAMADA DE SAÍDA	1	-0,004403732	7,34E-05	-2,51E-06	-0,173593552	-0,00791003	-8,55E-08	-0,173593555	-0,34725992	-0,5286901	0,34718701

Anexo 11. Bias para a camada oculta da Época 2 (Informação ao nível de pixel).

BIAS PARA A CAMADA OCULTA		
NEURÔNIOS DA CAMADA OCULTA	1	4,83772351
	2	-1,92045217
	3	6,18863076
	4	16,3954515
	5	-30,1117189
	6	3,5560658
	7	24,3231797
	8	-5,5687291
	9	69,709662
	10	25,6114535

Anexo 12. Bias para a camada de saída da Época 2 (Informação ao nível de pixel).

BIAS PARA A CAMADA DE SAÍDA		
NEURÔNIO DA CAMADA DE SAÍDA	1	0,004405507

Anexo 13. *Script* executado em plataforma Matlab (The MathWorks Inc., 2010) que permite realizar a aprendizagem da RNA.

```

clear all
format long g
load EN.txt;           % Recupera la matriz de entrada
load SAL.txt;         % Recupera la matriz de salida deseada
load VALEN.txt;       % Datos de evaluación para a RNA
load VALSAL.txt;      % Recupera los datos a ser predichos sin escalonar
load TESTEN.txt;      % Datos de test
load TESTSAL.txt;     % Datos de comprobación de los puntos test
%
%
% TRASPOCISIÓN DE MATRICES

P=EN';                % Coloca el archivo "EN" como traspuesta de la matriz en
                    % la variable "P"
                    % que contiene valores de la media espectral de los
                    % pixeles de cada
                    % segmento para los datos de entrada del entrenamiento

T=SAL';               % Coloca el archivo "N" como traspuesta de la matriz en la
                    % variable "T"
                    % que contiene valores de deforestación, donde 1=def;
                    % 0=nodef para los
                    % datos de salida del entrenamiento

E=VALEN';             % Coloca el archivo "VALEN" como traspuesta de la matriz
                    % en la variable
                    % "E" que contiene valores de la media espectral de los
                    % pixeles de cada
                    % segmento para los datos de entrada de la validación

S=VALSAL';           % Coloca el archivo "VALN" como traspuesta de la matriz en
                    % la variable
                    % "S" que contiene valores de deforestación, donde 1=def;
                    % 0=nodef para
                    % los datos de salida de la validación

tese=TESTEN';        % Coloca el archivo "TESTEN" como traspuesta de la
                    % matriz en la variable
                    % "tese" que contiene valores de la media espectral de los
                    % pixeles de
                    % cada segmento para los datos de entrada de testeo

testsal=TESTSAL';    % Coloca el archivo "TESTEN" como traspuesta de la matriz
                    % en la variable
                    % "tese" que contiene valores de la media espectral de los
                    % pixeles de
                    % cada segmento para los datos de salida de testeo

%

```

```

% NORMALIZACION DE MATRICES

[pnor,pp]=mapstd(P);
    % Normaliza la matriz "P", almacena en "pnor" la matriz
normalizada
    % y en "pp" los parámetros de la normalización
    % (Datos de entrada del entrenamiento)

%tnor=T;

[tnor,tt]=mapstd(T);
    % Normaliza la matriz "T", almacena en "tnor" la matriz
normalizada
    % y en "tt" los parámetros de la normalización
    % (Datos de salida del entrenamiento)

enor=mapstd('apply',E,pp);
    % Aplica los parámetros de normalización para las entradas
a la matriz
    % "E", que son las entradas para los datos de validación y
almacena
    % los resultados de la normalización en la matriz "enor"

salnor=mapstd('apply',S,tt);
    % Aplica los parámetros de normalización para las salidas
a la matriz
    % "S", que son las salidas para los datos de validación y
almacena
    % los resultados de la normalización en la matriz "salnor"

Val.P=enor; % La matriz "enor" es transferida al componente "Val.P" de
la
    % matriz compuesta "Val"

Val.T=salnor;% La matriz "salnor" es transferida al componente "Val.T"
de la matriz
    % compuesta "Val"

tesenor=mapstd ('apply',tese,pp);
    % Aplica los parámetros de normalización para las entradas
a la
    % matriz "tesenor", que son las entradas para los datos de
test y
    % almacena los resultados de la normalización en la matriz
"tesenor"

testsalnor=mapstd ('apply',testsal,tt);
    % Aplica los parámetros de normalización para las salidas
a la
    % matriz "testsalnor", que son las salidas para los datos
de test y
    % almacena los resultados de la normalización en la matriz
"testsalnor"

Test.P=tesenor;
    % La matriz "tesenor" es transferida al componente
"Test.P" de la
    % matriz compuesta "Test"

```

```

Test.T=testsalnor;
    % La matriz "testsalnor" es transferida al componente
    "Test.T"
    % de la matriz compuesta "Test"

%ESTABLECIMIENTO DE VALORES PARA LA PARADA DEL ENTRENAMIENTO

minval=1;
maxval=1;
minimo_test=1;
maximo_test=1;
min_ent=1;
max_ent=1;

while((minval>0.05 || minval<-0.05)|| (maxval>0.05 || maxval<-0.05)||
(minimo_test>0.05 || minimo_test<-0.05)|| (maximo_test>0.05 ||
maximo_test<-0.05)|| (min_ent>0.05 || min_ent<-0.05)|| (max_ent>0.05 ||
max_ent<-0.05))

% ESTRUCTURA DE LA RED NEURONAL ARTIFICIAL
% _____

net=newff(minmax(pnor), [10 1], {'tansig' 'purelin'}, 'trainlm');
    % Crea una red neuronal artificial feed forward, considera
    los valores
    % máximos y mínimos de la matriz de los valores de entrada
    de los datos
    % de entrenamiento ("pnor"), se define el número de
    neuronas en la capa
    % oculta y el número de neuronas en la capa de salida,
    también
    % se define las funciones de transferencia de la capa
    oculta
    % tansig: Hyperbolic tangent sigmoid transfer function) y
    la capa de
    % salida (purelin: Linear transfer function) y el
    algoritmo de
    % entrenamiento de la red (trainlm: Levenberg-Marquardt
    backpropagation).

% _____

% PROCESO DE ENTRENAMIENTO

net.trainParam.epochs = 1000;
    % Determina el número máximo de épocas o iteraciones en el
    % entrenamiento de la RNA.

net.trainParam.show = 1;
    % Define el intervalo de muestra del proceso de
    entrenamiento.
    % Cada "cuantas épocas muestra el gráfico"

net.trainParam.goal= 0;
    % Define la meta en el entrenamiento de la RNA.
    % Ese valor es la meta de entrenamiento

```

```

net.trainParam.time= inf;
    % Define el tiempo de duración del entrenamiento de la
    RNA.

net = init(net); % Inicializa a la RNA

[net,tr] = train(net,pnor,tnor,[],[],Val,Test);
    % Realiza el entrenamiento de la RNA, toma como argumentos
    la
    % RNA definida ("red"), la matriz normalizada de los datos
    de entrada
    % para el conjunto de entrenamiento ("pnor"); la matriz no
    normalizada de
    % los datos de salida del conjunto de entrenamiento
    ("tnor"), la matriz
    % compuesta por los datos normalizados de entrada
    ("Val.P") y salida ("Val.T")
    % del conjunto de validación ("Val") y la matriz compuesta
    por los datos
    % normalizados de entrada ("Test.P") del conjunto de test
    ("Test").

plotperf(tr); % Plotea el desempeño del entrenamiento de la RNA.

Y1=sim(net,pnor); % Genera salidas en la RNA entrenada, tomando como
    entradas
    % los datos normalizados del conjunto de
    entrenamiento("pnor")

save redn.mat; % Guarda en un archivo .mat ("RNA.mat") los
    parámetros de la RNA entrenada
net;

hold on;

peso1=net.iw{1}; % Coloca en la matriz "peso1" los pesos obtenidos
    para
    % la capa oculta de la RNA entrenada
peso2=net.lw{2}; % Coloca en la matriz "peso2" los pesos obtenidos
    para
    % la capa de salida de la RNA entrenada

% Coloca en un vector los bias de la capa oculta BIAS1, y de la capa
de salida BIAS2

bias1=net.b{1}; % Coloca en la matriz "bias1" los bias obtenidos para
    la
    % capa oculta de la RNA entrenada.

bias2=net.b{2}; % Coloca en la matriz "bias2" los bias obtenidos para
    la
    % capa de salida de la RNA entrenada.

% _____

% EVALUACION DE LA RNA ENTRENADA EN LOS PUNTOS DE CONTROL

Yval=sim(net,enor); % Se obtiene las medias espectrales de los

```

```

segmentos
% normalizadas correspondientes a los datos de
entrada del
% conjunto de validación por medio de la RNA
entrenada
% y las coloca en la variable "Yval"

Ytes=sim(net,tesenor); % Se obtiene las medias espectrales de los
segmentos
% normalizadas correspondientes a los datos de entrada
del
% conjunto de test por medio de la RNA entrenada y las
% coloca en la variable "Yval"

% _____

% DESNORMALIZACIÓN DE LAS MATRICES DE SALIDA

sal_entcol=mapstd('reverse',Yl,tt);

sal_testcol=mapstd('reverse',Ytes,tt);
% Coloca en la matriz "sal_testcol" la traspuesta
de la
% matriz "Ytest" que contiene los valores de
salida
% obtenidos de la RNA para las entradas del
conjunto
% de test.

sal_valcol=mapstd('reverse',Yval,tt);
% Coloca en la matriz "sal_valcol" la traspuesta
de la
% matriz "Yval" que contiene los valores de salida
% obtenidos de la RNA para las entradas del
conjunto
% de validación.

difent=sal_entcol' - SAL;
% Almacena en la matriz "difent" las diferencias
% entre los valores de

diftest=sal_testcol'-TESTSAL;
% Almacena en la matriz "diftest" las diferencias
entre
% los valores de ondulación geoidal proporcionados
por
% la RNA para los datos de entrada del conjunto de
test
% y los valores de ondulación geoidal provenientes
de
% los datos de salida para el conjunto de test.

difval=sal_valcol'-VALSAL;
% Almacena en la matriz "difval" las diferencias
entre
% los valores de ondulación geoidal proporcionados
por
% la RNA para los datos de entrada del conjunto de
% validación y los valores de ondulación geoidal

```

```
                                % provenientes de los datos de salida para el  
conjunto de validación
```

```
% _____
```

```
mediaent=mean(difent);  
mediaval=mean(difval);  
mediatest=mean(diftest);  
desvtent=std(difent);  
desvtval=std(difval);  
desvttest=std(diftest);
```

```
min_ent=min(difent)  
max_ent=max(difent)  
minimo_test=min(diftest)  
maximo_test=max(diftest)  
minval=min(difval)  
maxval=max(difval)
```

```
save redn.mat;  
save net.mat;  
save pp.mat;  
save tt.mat;
```

```
%%% _____  
end
```