

UNIVERSIDADE FEDERAL DO RIO DE JANEIRO
INSTITUTO DE MATEMÁTICA
NÚCLEO DE COMPUTAÇÃO ELETRÔNICA
PROGRAMA DE PÓS-GRADUAÇÃO EM INFORMÁTICA

PAULO CESAR DA COSTA MOTA

Uma Metodologia para Análise de Séries Temporais do Sensor MODIS

RIO DE JANEIRO

2009

Paulo Cesar da Costa Mota

UMA METODOLOGIA PARA ANÁLISE DE SÉRIES TEMPORAIS
DO SENSOR MODIS.

Dissertação de Mestrado apresentada ao Programa de Pós-Graduação em Informática, Instituto de Matemática, Núcleo de Computação Eletrônica, Universidade Federal, do Rio de Janeiro, como parte dos requisitos necessários à obtenção do título de Mestre em Informática.

Orientadores: Adriano Joaquim de Oliveira Cruz,
Carlo Emmanoel Tolla de Oliveira,

Co-orientador: Ubiratan Porto dos Santos,

Rio de Janeiro
2009

M917 Mota, Paulo Cesar da Costa

Uma metodologia para análise de séries temporais do sensor
MODIS / Paulo Cesar da Costa Mota. – 2009.
137 f. il.

Dissertação (Mestrado em Informática) – Universidade Federal
do Rio de Janeiro, Instituto de Matemática, Núcleo de Computação
Eletrônica, 2009.

Orientadores: Adriano Joaquim de Oliveira Cruz
Carlo Emmanoel Tolla de Oliveira
Co-orientador: Ubiratan Porto dos Santos

1. Sensor MODIS – Teses. 2. Análise de Séries Temporais – Teses.
I. Adriano Joaquim de Oliveira Cruz (Orient.) II. Carlo Emmanoel
Tolla de Oliveira (Orient.). III. Ubiratan Porto dos Santos (Co-orient.).
IV. Universidade Federal do Rio de Janeiro, Instituto de Matemática,
Núcleo de Computação Eletrônica. V. Título

CDD

Paulo Cesar da Costa Mota

UMA METODOLOGIA PARA ANÁLISE DE SÉRIES TEMPORAIS
DO SENSOR MODIS

Dissertação de Mestrado apresentada ao Programa de Pós-Graduação em Informática,
Instituto de Matemática, Núcleo de Computação Eletrônica, Universidade Federal do Rio de
Janeiro, como parte dos requisitos necessários à obtenção do título de Mestre em
Informática

Rio de Janeiro, 20 de agosto de 2009.

Prof. Adriano Joaquim de Oliveira Cruz, Ph.D., IM / UFRJ

Prof. Carlo Emmanoel Tolla de Oliveira, Ph.D., PPGI/UFRJ

Prof. Ubiratan Porto dos Santos, Ph.D., UFRJ

Prof^a. Margareth Simões Penello Meirelles, D.Sc., UERJ

Prof^a. Luziane Ferreira de Mendonça, D.Sc., IM / UFRJ

Prof. Josefino Cabral Melo Lima, D.Sc., IM / UFRJ

À minha mãe e à minha irmã Lucy ...

AGRADECIMENTOS

A Deus e aos Santos de devoção pela ajuda nas dificuldades da vida e proteção.

À minha mãe pelo amor e determinação em sempre proporcionar as melhores condições possíveis para o meu crescimento. Sempre te amarei.

À minha irmã Lucy, por ter sido minha irmã, minha mãe e meu pai nos momentos mais necessários além de ser responsável direta por tudo de bom que eu sou, conquistei e possa a vir conquistar. Você sempre estará em meu coração.

Ao meu pai pelo exemplo de honestidade e trabalho.

Ao meu irmão Manoel pela convivência e amizade.

Ao meu orientador Prof. Carlo Emmanoel pela oportunidade, sugestões, paciência e contagiante entusiasmo.

Ao meu orientador Prof. Ubiratan pelas sugestões e cooperação.

Ao Prof. Adriano por ter aceitado ser meu orientador.

Aos professores Cabral, Luziane e Margareth por me honrarem com suas participações na banca.

Ao pessoal da EMBRAPA (Prof.^a Margareth, Milton e Damien) pelas dicas e dados de campo.

Ao NCE e ao Instituto de Matemática por me aceitarem como aluno e me proporcionarem a alegria de voltar ao meio acadêmico.

RESUMO

MOTA, Paulo Cesar da Costa. **Uma metodologia para análise de séries temporais do sensor MODIS**. 2009. 137 f. Dissertação (Mestrado em Informática) _ Instituto de Matemática, Núcleo de Computação Eletrônica, Universidade Federal do Rio de Janeiro, Rio de Janeiro 2009.

Cada vez mais, se torna necessário o conhecimento freqüente do uso e cobertura do solo em larga escala e baixo custo. Entretanto as metodologias atualmente disponíveis carecem de mecanismos como: redução da dimensionalidade dos dados, alto grau de automação, análise da mistura espectral, independência de especialistas em sensoriamento remoto e informática, e flexibilidade. Esses temas são abordados de forma isolada, exigindo uma grande iteração do usuário em etapas, nas quais são necessários conhecimentos específicos, notadamente, nas fases de treinamento, levantamento das características dos dados em análise e seleção das amostras. Outro fator importante está ligado aos custos computacional e financeiro agregados a essas metodologias, que dificultam o acesso de regiões mais carentes a informações preciosas. O custo financeiro está relacionado à aquisição das imagens e aos especialistas necessários nas diferentes abordagens. Desta forma, as imagens de menor custo são de baixa ou media resolução, requerendo um tratamento específico para este problema. A fenologia das espécies também é uma característica considerável, já que uma espécie pode possuir assinaturas espectrais distintas em datas diferentes. Com base nisto, esta dissertação pretende propor uma metodologia que, fazendo uso das séries temporais gratuitas do sensor MODIS (*Moderate Resolution Imaging Spectroradiometer*), da transformada *wavelet* na redução da dimensionalidade dos dados, da automação de todo o processo e usando técnicas de inteligência computacional (Redes Neurais, Lógica Nebulosa e ANFIS), aborde os problemas relacionados e forneça uma classificação do uso e cobertura do solo flexível, de baixo custo e alto grau de automação.

A avaliação da metodologia proposta foi realizada através de um estudo de caso para uma região do estado de Mato Grosso, com uma extensão de cerca de 125.000 Km², evidenciando o potencial da metodologia em obter classificações

robustas, flexíveis e automatizadas em larga escala de séries temporais do sensor MODIS.

ABSTRACT

MOTA, Paulo Cesar da Costa. **Uma metodologia para análise de séries temporais do sensor MODIS**. 2009. 137 f. Dissertação (Mestrado em Informática) _ Instituto de Matemática, Núcleo de Computação Eletrônica, Universidade Federal do Rio de Janeiro, Rio de Janeiro 2009.

It becomes more and more necessary the large scale and low costs when it comes to common knowledge of land use and land cover. However, the currently available methodologies lack mechanisms such as: dimensionality reduction of data, highly automatized approach, spectral mixture analysis, in remote sensing and computer experts independence, and flexibility. These topics are approached in isolation, requiring a great user's iteration in steps, in which are required expertise knowledge, especially during training, extraction of feature and selection of sample. Another important factor are the computational and financial costs added to these methodologies making it difficult to access valuable information for poor regions. The financial cost is related to the acquisition of images and the needed specialists for the different approaches. The lower cost images which have low or medium resolution, require a specific treatment for this problem. The specie's phenology is also a significant feature, as species can have different spectral signatures in different dates. Thus, this thesis aims to propose a methodology which makes use of free time series of MODIS (Moderate Resolution Imaging Spectroradiometer) sensor, the wavelet transform to reduce the dimensionality of the data, the automation of the whole process and using techniques of computational intelligence (Neural Network, Fuzzy Logic and ANFIS) to approach these problems and provide a flexible, low cost and highly automated classification of land use and cover.

The evaluation of the proposed methodology was performed using a case study of a region from the state of Mato Grosso, Brazil with a area of about 125,000 Km² highlighting the potential of the methodology to obtain robust, flexible and automated time series classification of MODIS sensor in large-scale regions.

SUMÁRIO

1	INTRODUÇÃO	1
1.1	OBJETIVOS	3
1.2	ORGANIZAÇÃO DA DISSERTAÇÃO.....	3
2	FUNDAMENTAÇÃO TEÓRICA	5
2.1	SENSORIAMENTO REMOTO.....	5
2.1.1	<i>Conceitos Básicos.....</i>	5
2.1.2	<i>Índices de Vegetação.....</i>	8
2.2	SENSOR MODIS	14
2.2.1	<i>Produto MOD13Q1</i>	17
2.3	PRÉ –PROCESSAMENTO	18
2.4	TRANSFORMADA <i>WAVELET</i>	19
2.5	REDES NEURAIS.....	25
2.5.1	<i>Arquitetura</i>	29
2.5.2	<i>Aprendizado.....</i>	31
2.5.3	<i>Mapa Auto Organizável de Kohonen</i>	33
2.6	LÓGICA NEBULOSA.....	36
2.7	SISTEMAS HÍBRIDOS (NEURO-NEBULOSOS).....	46
2.7.1	<i>Sistema Neuro-Nebuloso de Inferência Adaptativo (ANFIS)</i>	47
2.8	RECONHECIMENTO DE PADRÕES	49
2.8.1	<i>Métodos não supervisionados</i>	50
2.8.1.1	<i>Validação.....</i>	53
2.8.2	<i>Métodos Supervisionados</i>	56
2.8.2.1	<i>Avaliação.....</i>	57
3	TRABALHOS RELACIONADOS	59
4	METODOLOGIA	62
5	ESTUDO DE CASO.....	73
5.1	DADOS SIMULADOS	74
5.1.1	<i>Materiais.....</i>	74
5.1.2	<i>Aplicação da metodologia e avaliação.</i>	74

5.2	ESTUDO DE CASO COM DADOS REAIS	80
5.2.1	<i>Materiais</i>	81
5.2.2	<i>Aplicação da metodologia e avaliação</i>	83
6	CONCLUSÕES	93
6.1	DADOS SIMULADOS	93
6.2	DADOS REAIS	93
6.3	TRABALHOS FUTUROS.....	96
	REFERÊNCIAS	97

LISTA DE FIGURAS

Figura 2.1 Janelas Atmosféricas	7
Figura 2.2 Assinatura Espectral de uma Folha Verde	7
Figura 2.3 Exemplo de Calculo do NDVI	11
Figura 2.4 NDVI na Superfície Terrestre	17
Figura 2.5 <i>Wavelet</i> Haar	20
Figura 2.6 <i>Wavelet</i> de Daubechies (db2, db4,db8) da esquerda para a direita.....	21
Figura 2.7 <i>Wavelet</i> de Morlet.....	21
Figura 2.8 A Curva Chapéu Mexicano.....	21
Figura 2.9 Transformada de Fourier	22
Figura 2.10 Transformada <i>Wavelet</i> com Uso de Filtros	25
Figura 2.11 Modelo Genérico de Neurônio Artificial	26
Figura 2.12 Tipos de Camadas em Uma Rede Neural	30
Figura 2.13 Topologia Unidirecional.....	31
Figura 2.14 Topologia Recorrente	31
Figura 2.15 Exemplo de Topologia de Mapa de Kohonen.....	34
Figura 2.16 Suporte Compacto e Não Compacto	38
Figura 2.17 Conceito de Distancia	39
Figura 2.18 Variável lingüística relativa ao desempenho de um aluno em relação a sua nota.....	42
Figura 2.19 Exemplo de Sistema de Inferência Nebuloso	45
Figura 2.20 Arquitetura ANFIS.....	48
Figura 2.21 Estrutura Básica de um Sistema de Reconhecimento de Padrões.....	50
Figura 4.1 Visão Geral da Metodologia	62
Figura 4.2 Fase de Pré-processamento	63
Figura 4.3 Agrupamento com Coef. <i>Wavelet</i> a esquerda e com Dados Originais a direita.....	66
Figura 4.4 Seleção das Amostras	67
Figura 4.5 Visão da Fase de Classificação	69
Figura 4.6 Fluxograma da metodologia.....	71

Figura 5.1 Perfis das Classes Feijão1 e Feijão1R.....	76
Figura 5.2 Perfis das Classes Milho e Sorgo (com e sem ruído)	77
Figura 5.3 Perfis das Classes Feijão1 e Feijão1 com Ruído de 20%.....	79
Figura 5.4 Levantamento de campo	82
Figura 5.5 Estado Mato Grosso com a Área de Estudo Representada no Retângulo Escuro	83
Figura 5.6 As linhas mais Grossas Representam as Amostras de Cana em Laranja e Soja em Amarelo, as Linhas mais Finas as Séries Classificadas.....	91
Figura 5.7 As Linhas mais Grossas Representam as Amostras de Algodão em Laranja e Soja em Amarelo, as Linhas mais Finas as Séries Classificadas	91
Figura 5.8 Mapa das Classes Agrícolas	92

LISTA DE TABELAS

Tabela 2.1 Bandas do Sensor MODIS e Suas Aplicações	15
Tabela 2.2 Características do Produto MOD13Q1	17
Tabela 2.3 Funções de Propagação	27
Tabela 2.4 Principais T-Normas e T-Conormas.....	40
Tabela 2.5 interpretação dos valores do coeficiente kappa	59
Tabela 5.1 Matriz de confusão de uma classificação hibrida usando Kohonen	75
Tabela 5.2 Matriz de Confusão com grau de Inclusão com limiar em 0.8	77
Tabela 5.3 Matriz de Confusão com grau de Inclusão com limiar em 0.7	78
Tabela 5.4 Matriz de Confusão de uma Classificação com o sistema ANFIS	79
Tabela 5.5 Classificação com o Sistema ANFIS considerando amostra de Sorgo com ruído.....	80
Tabela 5.6 Quantidade de Perfis Para as Classes de Interesse	84
Tabela 5.7 Classificação com Coeficientes <i>Wavelet</i>	85
Tabela 5.8 Classificação com Dados Originais.....	85
Tabela 5.9 Classificação com o Sistema ANFIS com Regras automáticas	86
Tabela 5.10 Classificação com o sistema ANFIS com adição de regra	87
Tabela 5.11 Classificação usando Kohonen com união de classes.....	88
Tabela 5.12 Classificação usando o sistema ANFIS com União de Classes	88
Tabela 5.13 Classificação Nebulosa Considerando o Maior Grau de Inclusão.....	89
Tabela 5.14 Classificação Nebulosa Considerando Grau de Inclusão Maior que 0.6	90
Tabela 5.15 Classificação Nebulosa Considerando Grau de Inclusão Maior que 0.8	90

1 Introdução

Atualmente a existência de fenômenos como aquecimento global, desmatamentos, poluição e escassez de alimentos, evidenciam, de forma cada vez mais premente, a necessidade de uma melhor relação do homem com o uso e cobertura do solo, objetivando assim, uma melhor qualidade de vida e em um futuro não muito longínquo a sobrevivência da própria espécie, despertando desta forma, interesse de várias áreas de pesquisa. Todavia, apesar desta relevância, o mapeamento do uso e cobertura do solo em larga escala ainda se constitui um tema desafiador nos dias atuais.

Vários trabalhos têm demonstrado a eficiência da utilização de imagens de sensoriamento remoto de alta resolução para a classificação do uso e cobertura do solo a nível local. Por outro lado, confirmou-se os altos custos computacionais e financeiros na análise freqüente de grandes áreas, principalmente para as regiões mais carentes do Brasil e do mundo. Devido a isto, ao longo dos anos o levantamento do uso e cobertura do solo a partir de imagens de baixo custo, alta resolução temporal e baixa ou moderada resolução espacial também foram alvo de estudos, obtendo-se relativo sucesso com estas imagens.

Entretanto essas abordagens esbarram em fortes limitações quando aplicadas em escalas regionais, principalmente no que se concerne à baixa resolução espacial dos sensores utilizados e a falta de um tratamento eficiente da grande massa de dados provenientes dessas tecnologias, advindas do fato dessas metodologias não se preocuparem com mecanismos como: redução da dimensionalidade dos dados, flexibilidade, alto grau de automação, diminuição da interferência humana na seleção das amostras e a mistura de pixels nas regiões de fronteiras entre classes. Além desses métodos não se preocuparem muito com as classes pouco discrimináveis, normalmente classificando-as em um único grupo, em detrimento a uma classificação mais abrangente. Outro fato relevante é que essas metodologias não se adequam aos

recursos disponíveis, impedindo, desta forma, o seu uso ou, em contrapartida, não fazendo um bom aproveitamento dos recursos possíveis.

De outra forma, mais recentemente o Sensor MODIS (*Moderate Resolution Imaging Spectroradiometer*), concebido para levantamento de grandes áreas e que se encontra a bordo dos satélites *Terra* e *Aqua* da NASA (*National Aeronautics and Space Administration*, a agência espacial dos EUA), através de seus dados e produtos acabados vem se tornando uma alternativa viável para esse tipo de abordagem. Esse sensor em relação aos seus predecessores apresenta uma maior resolução espacial (250m nas faixas do vermelho e infravermelho próximo) e padrões superiores de calibração, georreferenciamento e correção atmosférica; além de informações específicas a respeito da qualidade de seus dados, aliados a gratuidade de seus produtos e a uma cobertura quase diária de todos os pontos da superfície terrestre (resolução temporal). Caracterizando dessa forma, sua alta relevância na análise do uso e cobertura do solo sobre grandes regiões.

Todavia, o desenvolvimento desta tecnologia, pelos mesmos motivos das anteriores, ainda não encontra respaldo em metodologias que propiciem sua utilização em levantamentos regionais freqüentes e que sejam financeiramente acessíveis as regiões mais carentes destes recursos.

Outro fato relevante, em muitas destas abordagens, é o uso de várias ferramentas diferentes e até mesmo mais de um sistema operacional, tornando difícil a adaptação para um ambiente integrado que facilite e estimule o usuário que normalmente não é da área de computação à plena utilização desses métodos. Isto leva a uma rigidez que não considera os recursos do usuário, impossibilitando que estes métodos sejam executados em plataformas mais modestas e não aproveitando por outro lado os recursos das plataformas mais robustas.

Partindo-se da premissa que com o uso de imagens gratuitas do sensor MODIS, técnicas de Inteligência Computacional, utilização da Transformada *Wavelet* e automatização da seleção das amostras, seja possível se obter uma abordagem flexível, de bom desempenho e que gere uma classificação adequada para o estudo do uso e cobertura do solo com alto grau de automatização, esta dissertação pretende propor uma metodologia que aborde estes problemas de forma simples e objetiva.

São fontes de motivação: a relevância do tema e aplicação de conhecimentos de inteligência computacional na busca de soluções para uma área carente e de primordial importância.

1.1 Objetivos

Este trabalho tem como objetivo geral o desenvolvimento de uma metodologia de baixo custo, flexível e de fácil aplicação que automatize o processo de interpretação de uma seqüência de imagens temporais do sensor MODIS para a classificação do uso e cobertura do solo com um desempenho aceitável, sendo adaptável a várias situações, e que minimize a interferência humana no processo, bem como a análise da metodologia e das tecnologias envolvidas.

Pode-se relatar ainda como objetivos específicos: a avaliação do sensor MODIS para o estudo do uso e cobertura do solo em larga escala, a avaliação do uso da Transformada *Wavelet* na redução da dimensionalidade dos dados, a proposição de um método para a seleção automática dos dados de treinamento, a análise de alguns algoritmos de agrupamento, proposta de uma abordagem via uso de Lógica Nebulosa na consistência da classificação e na análise da mistura de classes, a avaliação do uso de Redes Neurais, a análise da geração automática de um modelo nebuloso a partir de um sistema adaptativo (ANFIS), a obtenção de um bom grau de automação e flexibilidade no concernente a classificação e também quanto aos diversos níveis de plataformas, e a realização de um estudo de caso utilizando a metodologia proposta.

1.2 Organização da dissertação

Além deste capítulo de introdução, esta dissertação se compõe de mais cinco capítulos. No segundo capítulo, serão abordados os conhecimentos básicos relevantes ao entendimento da metodologia proposta. Sendo descritas as principais tecnologias envolvidas no trabalho, como: pré-processamento de imagens, noções de Sensoriamento Remoto, Transformada *Wavelet*, Redes Neurais, Lógica Nebulosa, sistema ANFIS, e conceitos relativos a agrupamentos e classificação. O terceiro capítulo relata os principais trabalhos relacionados com a metodologia. A descrição da

metodologia em detalhes será fornecida no quarto capítulo. O quinto capítulo abordará os estudos de casos relativos aos dados simulados e aos dados reais. No sexto capítulo, serão relatadas as conclusões sobre os estudos de casos com dados simulados e dados reais e as propostas para trabalhos futuros.

2 Fundamentação Teórica

Este capítulo descreve o conhecimento básico necessário a compreensão das principais tecnologias envolvidas na metodologia. A seção 2.1 relata as características mais importantes do Sensoriamento Remoto. Na seção 2.2, os principais aspectos do sensor MODIS e do produto MOD13Q1 são descritos. As principais técnicas de pré-processamento são abordadas na seção 2.3. Os principais tópicos relacionados às funções *wavelet* e a Transformada *Wavelet* são descritos na seção 2.4. Na seção 2.5, são abordadas as principais características das Redes Neurais. A seção 2.6 descreve os conceitos mais importantes da Lógica Nebulosa. Na seção 2.7, são abordados os sistemas híbridos e especificamente o ANFIS. A seção 2.8 descreve os principais conceitos relacionados ao reconhecimento de padrões.

2.1 Sensoriamento Remoto

Nesta seção são abordados os principais conceitos de Sensoriamento Remoto relacionados à metodologia. Na subseção 2.1.1 são abordados os conceitos básicos e a subseção 2.1.2 relata os principais índices de vegetação.

2.1.1 Conceitos Básicos

Segundo (MATHER, 2004), a ciência do Sensoriamento Remoto compreende a análise e interpretação das medições das radiações eletromagnéticas que são emitidas ou refletidas por um alvo, sendo observadas ou gravadas a partir de um ponto estratégico por um observador ou instrumento que não está em contato com o alvo.

O Sensoriamento Remoto tem sua fundamentação na propagação de ondas eletromagnéticas e na sua interação com os alvos naturais (aerossóis, superfícies terrestres e aquáticas, nuvens, etc.). A principal fonte de energia para o sensoriamento remoto é a energia solar. Ao interagir com o sistema Terra-atmosfera, a radiação solar sofre uma série de transformações sendo então re-emitida para o espaço na forma de radiação terrestre.

O espectro eletromagnético compreende uma vasta gama de comprimentos de onda, classificados por bandas: raios gama, raios X, ultravioleta, visível, infravermelho, microondas e ondas de rádio (MATHER, 2004).

A banda da luz visível compreende as radiações perceptíveis pelo olho humano.

A banda do ultravioleta é formada por radiações mais energéticas que a luz (tem menor comprimento de onda), por isso, penetra mais profundamente na pele, sendo causa de queimaduras quando esta é exposta excessivamente ao sol.

A banda de raios X é mais energética que a ultravioleta e mais penetrante, sendo por, este motivo, utilizada na medicina para produção de imagens do interior do corpo humano.

As radiações do espectro infravermelho são produzidas intensamente pelo sol, mas podem também serem geradas por objetos aquecidos (lâmpadas).

No processo de interação com um objeto, a energia pode ser refletida, absorvida ou transmitida (objetos transparentes). De forma geral a parte absorvida se transforma em calor ou outro tipo de energia e a parte refletida se espalha pelo espaço. Resultando em três conceitos importantes:

- i. Refletância – fator que mede a capacidade de um objeto refletir a energia radiante que incide sobre ele.
- ii. Absortância – capacidade de um objeto absorver energia radiante.
- iii. Transmitância – capacidade de um objeto transmitir energia.

Devemos considerar também, os efeitos das interações da radiação com a atmosfera, pois antes de atingir a superfície, a radiação pode ser afetada por partículas e gases na atmosfera. Estes efeitos são causados principalmente por fenômenos como espalhamento ou absorção.

O Espalhamento é a interação da radiação eletromagnética com partículas ou grandes moléculas de gases presentes na atmosfera, acarretando o redirecionamento de sua trajetória inicial.

A Absorção é o fenômeno em que a energia, em vários comprimentos de onda, é absorvida por moléculas de elementos como: Ozônio, dióxido de carbono e vapor d'água; presentes na atmosfera.

Ainda com relação ao Espalhamento pode-se afirmar que existem três tipos de ocorrência deste fenômeno: o Espalhamento Rayleigh que ocorre quando as partículas

presentes na atmosfera são muito menores que comprimentos de onda da radiação, o Espalhamento Mie que ocorre quando as partículas presentes na atmosfera são do exato tamanho do comprimento de onda da radiação e o Espalhamento Não-Seletivo que ocorre quando as partículas presentes na atmosfera são muito maiores que o comprimento de onda da radiação.

Dessa forma, devido à grande influência exercida pela atmosfera sobre a energia eletromagnética, os sensores remotos se utilizam de áreas, chamadas janelas (ultravioleta, visível e infravermelho), como visto na Figura 2.1, menos suscetíveis a esta interferência.

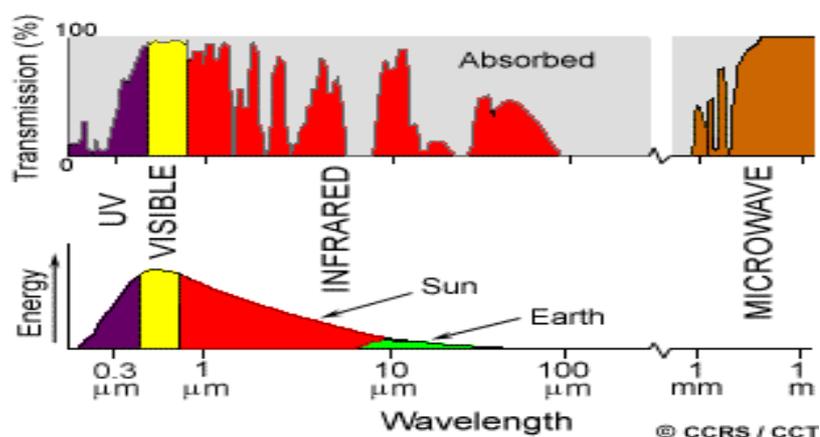


Figura 2.1 Janelas Atmosféricas

FONTE: (CCRS, 2006)

Outro conceito importante é o de assinatura espectral, que representa a variação da refletância de um objeto para cada diferente radiação que o atinge.

A figura abaixo mostra a assinatura espectral de uma folha verde.

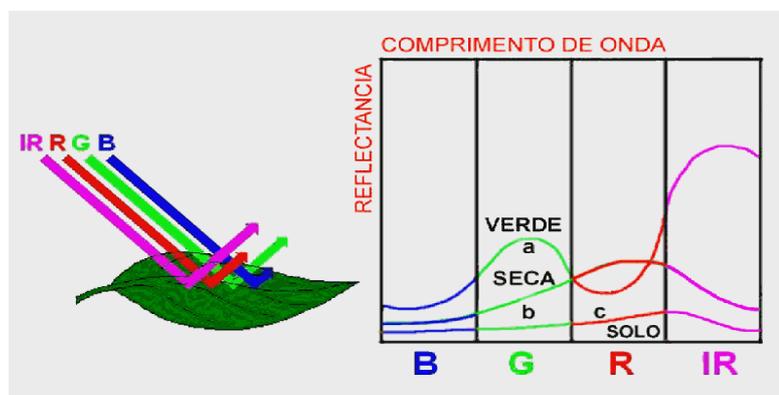


Figura 2.2 Assinatura Espectral de uma Folha Verde

Ao analisar a figura acima podemos constatar no nível da banda do visível uma maior refletância da banda G, fato este devido à aparência verde da folha. A alta refletância na banda IR, se explica pelos aspectos fisiológicos da folha e varia com o seu conteúdo de água na estrutura celular superficial, sendo um indicador de sua natureza, estágio de desenvolvimento e grau de preservação.

Outra definição importante é a de Sistemas Sensores que são os equipamentos a bordo dos satélites com a finalidade de capturar e registrar a energia eletromagnética propagada pelos objetos na superfície terrestre. A classificação mais usual para sensores é a que os discriminam quanto à capacidade de emitir a energia que irá interagir com os objetos, dividindo-os em dois tipos (MATHER, 2004):

- i. Passivos – são sensores que utilizam a energia de uma fonte externa (sol), são os mais comuns;
- ii. Ativos – são os que possuem a capacidade de emitir energia própria (radares).

Com relação às imagens podemos considerar os seguintes conceitos:

- i. Resolução Espacial – indica o tamanho do menor objeto que se pode representar na imagem;
- ii. Resolução Espectral – indica o número de faixas do espectro eletromagnético em que o sensor é capaz de atuar, ou seja, gerar níveis de cinza;
- iii. Resolução Temporal – é o intervalo de tempo necessário para um sistema sensor obter duas imagens consecutivas de uma mesma região;
- iv. Resolução Radiométrica – é a quantidade de bits utilizados para representar um nível de cinza da imagem.

2.1.2 Índices de Vegetação

A análise da vegetação e a detecção de mudanças em seus padrões são referências para avaliação e análise dos recursos naturais. Desta forma, a detecção e avaliação da quantidade de verde na vegetação é uma das principais aplicações do Sensoriamento Remoto no gerenciamento dos recursos ambientais e tomada de decisões (EASTMAN, 2001).

A vegetação verde saudável tem uma interação muito distinta na região do visível e do infravermelho próximo do espectro eletromagnético. Na região do visível os pigmentos das plantas, notadamente a clorofila, causam uma grande absorção de energia, principalmente para o efeito da fotossíntese. Este pico de absorção se concentra na área do azul e do vermelho do espectro visível, explicando assim, a cor verde das folhas. Entretanto na região do infravermelho ocorre uma situação muito diferente, a energia nesta região não é utilizada pela fotossíntese sendo fortemente refletida pela estrutura interna da maioria das folhas, resultando em uma alta refletância na região do infravermelho próximo. Este grande contraste de energia refletida, principalmente entre as regiões do vermelho e do infravermelho do espectro eletromagnético, tem sido alvo de uma grande variedade de tentativas de se desenvolver índices que representem a quantidade de vegetação, usando imagens de Sensoriamento Remoto.

Os mais usuais desses índices exploram a característica da absorção da clorofila da vegetação na porção do vermelho do espectro e na alta refletância da vegetação na porção do infravermelho próximo, devido a essas bandas conterem mais de 90% da informação do dossel de plantas (LEBLON, 1999). Um índice ideal deveria ser sensível apenas ao dossel da vegetação (parte verde), porém fatores como as propriedades ópticas do solo e a influência da atmosfera atuam de forma limitante na análise desses dados (LEBLON, 1999).

Os índices de vegetação sofrem interferência direta do ângulo zenital solar, da refletância do substrato, da estrutura do dossel e IAF (Índice de Área Foliar) e das características espectrais das folhas. Devido a estas características, estes índices apresentam os seguintes problemas: sensibilidade a muitas variáveis (efeitos atmosféricos, variação do brilho do solo com a umidade), sensibilidade as condições de iluminação e observação, valores diferentes para grandes distancias, diferentes satélites e datas diferentes.

Com relação às vantagens podemos relacionar: simplicidade de implementação, baixo custo computacional, redução do volume dos dados (dimensionalidade), fácil interpretação e eliminação de ruídos. Sendo assim, os índices de vegetação são recomendados para indicação da biomassa ou estimação

aproximada da cobertura vegetal e para processar grandes massas de dados em curto espaço de tempo ou baixo custo, não sendo indicados para estimação precisa da biomassa.

Segundo Jackson e Huete (HUETE, 1988; JACKSON, 1983) os índices de vegetação foram classificados em dois grupos: baseado na inclinação e na distância. Os índices baseados na inclinação são simplesmente combinações aritméticas que espelham o contraste da resposta espectral dos padrões de vegetação entre as áreas do vermelho e do infravermelho. Em contraste ao grupo baseado na inclinação, o grupo baseado na distância mede a quantidade de vegetação calculando a diferença da refletância em relação à refletância do solo descoberto.

Os índices baseados na inclinação mais usados são o NDVI e o EVI.

O índice de Vegetação Normalizada (NDVI) (ROUSE; HAAS; SCHELL *et al.*, 1973) tem o objetivo de separar o verde da vegetação do brilho do solo, expressando a diferença entre as bandas do infravermelho próximo e do vermelho normalizado pela soma destas bandas, resultando na seguinte fórmula:

$$\text{NDVI} = \frac{(\rho_{IVP} - \rho_V)}{(\rho_{IVP} + \rho_V)}$$

Onde:

ρ_{IVP} - refletância na região do infravermelho próximo;

ρ_V - refletância na região do vermelho.

O NDVI retém certas propriedades favoráveis que reduzem o ruído e a incerteza associada às características do instrumento e fontes externas de ruído (por exemplo, sombra de nuvem), mas existem certas desvantagens, como por exemplo: a não linearidade, problemas de saturação do sinal em regiões de alta concentração de biomassa e sensibilidade para expor fundos de solo em áreas de vegetação escassa.

Na Figura 2.3 observa-se um exemplo de cálculo do NDVI.

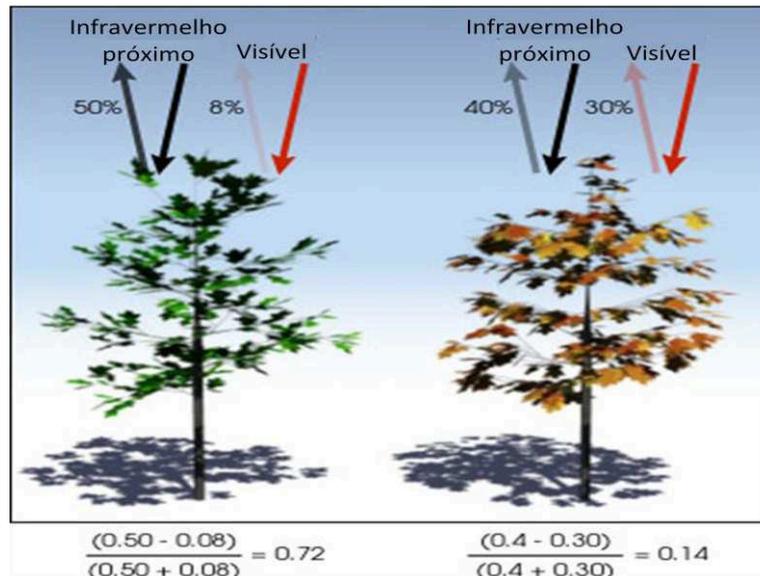


Figura 2.3 Exemplo de Cálculo do NDVI

FONTE: Adaptado (EOS, 2008)

O EVI foi desenvolvido para fazer parte dos produtos fornecidos pelo sensor MODIS, objetivando aperfeiçoar o sinal da vegetação, melhorando a sensibilidade em regiões com maiores densidades de biomassa, além do monitoramento da vegetação através da redução das influências atmosféricas e da influência do solo no dossel.

O EVI pode ser calculado através da seguinte equação:

$$EVI = G * \frac{\rho_{IVP} - \rho_V}{\rho_{IVP} + C_1 * \rho_V - C_2 * \rho_A + L}$$

Onde:

ρ_{IVP} - refletância na região do infravermelho próximo;

ρ_V - refletância na região do vermelho;

ρ_A - refletância do azul;

C_1 - coeficiente de ajuste para efeito de aerossóis da atmosfera no vermelho;

C_2 - coeficiente de ajuste para efeito de aerossóis da atmosfera no azul;

L = fator de ajuste para o solo;

G = fator de ganho.

Com relação aos índices baseados na distância, os mais comuns são o PVI e o SAVI.

O índice de vegetação perpendicular (PVI) (RICHARDSON; WIEGAND, 1977) relaciona a distância de cada pixel com a linha do Solo, sendo representado pela seguinte equação:

$$PVI = \left[\left(\frac{1}{\sqrt{a+1}} \right)^2 (\rho_{IV} - a * \rho_V - b) \right]$$

Onde:

ρ_{IV} - refletância na região do infravermelho;

ρ_V - refletância na região do vermelho;

a e b - coeficientes ajustados para a linha do solo.

O Índice de Vegetação Ajustado para o Solo (SAVI) (HUETE, 1988) tem como objetivo minimizar o efeito do solo sobre o sinal de vegetação, através de um fator de ajuste do efeito do solo no denominador da equação do NDVI. Este fator de ajuste depende da densidade de vegetação da área analisada. De acordo com (HUETE, 1988), o valor $L=0,25$ é utilizado para vegetações densas e $L=1$ para vegetações abertas, sendo $L=0,5$ um valor considerado ideal para um grande intervalo de condições de vegetação.

O SAVI se expressa na seguinte fórmula:

$$SAVI = \frac{\rho_{IVP} - \rho_V}{(\rho_{IVP} + \rho_V - L)} (1 + L)$$

Onde:

ρ_{IVP} - Refletância na região do infravermelho próximo;

ρ_V - Refletância na região do vermelho;

L – Fator de ajuste do solo.

As derivações dos índices de vegetação propiciaram novas abordagens que podem ser consideradas como um terceiro tipo de representação destes índices, as transformações ortogonais. Destas transformadas a mais conhecida é a *Tasseled Cap*.

Essa abordagem sintetiza uma transformação que descreve a trajetória espectro-temporal dos *pixels* em uma cena de determinada cultura agrícola, tornando possível isolar-se em imagens separadas e menos correlacionadas a quantidade dos componentes verde e amarelo (umidade) da vegetação e do brilho do solo no desenvolvimento de uma cultura específica. Resultando em imagens que traduzem diretamente as características físicas dos campos agrícolas. A primeira transformação gerada por Kauth e Thomas (KAUTH; THOMAS, 1976) utilizava dados do sensor MSS, gerando componentes que foram denominados de “*brighthness*”, “*greenness*”, “*yellowness*” e “*non-such*”. Com o lançamento do Landsat-4 com um sensor de 6 bandas refletivas, Crist e Cicone (CRIST; CICONE, 1984) relataram novas componentes no espaço hexadimensional, das quais somente as três primeiras, brilho (BR), verde (GR) e umidade (WT) tinham significado prático. Descritas nas seguintes equações:

$$BR=0,3037*tm1+0,2793*tm2+0,4743*tm3+0,5585*tm4+0,5082*tm5+0,1863*tm7$$

$$GR=-0,2848*tm1-0,2435*tm2-0,5436*tm3+0,7243*tm4+0,0840*tm5-0,1800*tm7$$

$$WT=0,1509*tm1+0,1973*tm2+0,3279*tm3+0,3406*tm4-0,7112*tm5-0,4572*tm7$$

Onde: tm1, tm2, tm3, tm4, tm5 e tm7 são os valores de refletância nas respectivas bandas do sensor; e BR, GR e WT são as componentes de brilho, vegetação e umidade. Os coeficientes são adaptados do trabalho de Kauth e Thomas (KAUTH; THOMAS, 1976).

O índice brilho (BR) está relacionado com a variação espectral dos solos, o verde (GR) relaciona-se ao vigor da vegetação e a componente umidade (WT) é o contraste entre o infravermelho médio e os demais canais. Entre as aplicações desta transformada podemos citar: a elaboração de uma boa base física para a análise de imagens agrícolas obtidas em diferentes estágios da cultura segundo afirma Mather (MATHER, 2004) e o mapeamento de espécies (idade e estrutura) descrito por Cohen (COHEN; SPIES; FIORELLA, 1995). Outro recurso desta técnica é a normalização radiométrica de imagens, desejável principalmente em imagens multitemporais, em algumas aplicações onde se faz necessária a eliminação do efeito variável da atmosfera e dos ângulos solares, bem como da degradação de detectores.

Adicionalmente, essa transformada possibilita a redução da dimensão de uma cena, permitindo um armazenamento dos dados mais eficiente e a independência da transformação em relação à cena, visto que os coeficientes das equações são pré-estabelecidos, podendo ser usados então como um importante método de análise multitemporal. Os coeficientes das equações podem ser adaptados para uma determinada região de interesse ou característica.

2.2 Sensor MODIS

O sensor MODIS (*Moderate Resolution Imaging Spectroradiometer*) encontra-se a bordo dos satélites Terra, lançado em 1999, e Aqua lançado em 2002, sendo concebido para atender os requisitos de três áreas de interesse: atmosfera, oceano e terra, objetivando fornecer dados abrangentes, realizando imageamentos de grandes áreas e de forma simultânea da superfície terrestre. Estes satélites fazem parte do programa EOS (*Earth Observing System*) da agência espacial norte-americana NASA.

O sensor MODIS possui uma alta sensibilidade radiométrica (12 bits) em 36 bandas, cujos comprimentos de onda variam de 0.4 μm a 14.4 μm . Com intuito de aperfeiçoar a precisão radiométrica e evitar os efeitos da absorção atmosférica, estas faixas espectrais foram especificadas bastante estreitas e bem definidas. A Tabela 2.1 relaciona as bandas do sensor e as suas principais aplicações.

Tabela 2.1 Bandas do Sensor MODIS e Suas Aplicações

Período de revisita	1 a 2 dias	
Altitude	705km	
Largura de faixa	2330km	
Resolução no NADIR	250m (bandas 1-2)	
	500m (bandas 3-7)	
	1km (bandas 8-36)	
<i>Canais</i>	<i>Bandas Espectrais</i>	<i>Principais Usos</i>
1. Vermelho	0,620 – 0,670 μm	Propriedades da superfície, das nuvens e dos aerossóis
2. IV próximo	0,841 – 0,876 μm	
3. Azul	0,459 – 0,479 μm	Propriedades da superfície, das nuvens e dos aerossóis
4. Verde	0,545 – 0,565 μm	
5. IV próximo	1,230 – 1,250 μm	
6. IV médio	1,628 – 1,652 μm	
7. IV médio	2,105 – 2,155 μm	
8.	0,405 – 0,420 μm	
9.	0,438 – 0,448 μm	
10.	0,483 – 0,493 μm	Cor oceânica Fitoplâncton Biogeoquímica
11.	0,526 – 0,536 μm	
12.	0,546 – 0,556 μm	
13.	0,662 – 0,672 μm	
14.	0,673 – 0,683 μm	
15.	0,743 – 0,753 μm	
16.	0,862 – 0,877 μm	
17.	0,890 – 0,920 μm	Vapor d'água na atmosfera
18.	0,931 – 0,941 μm	
19.	0,915 – 0,965 μm	
20.	3,660 – 3,840 μm	Temperatura de superfície Temperatura das nuvens
21.	3,929 – 3,989 μm	
22.	3,929 – 3,989 μm	
23.	4,020 – 4,080 μm	
24.	4,433 – 4,498 μm	Temperatura atmosférica
25.	4,482 – 4,549 μm	
26.	1,360 – 1,390 μm	Nuvens cirrus
27.	6,535 – 6,895 μm	Vapor d'água
28.	7,175 – 7,475 μm	
29.	8,400 – 8,700 μm	
30.	9,580 – 9,880 μm	Ozônio
31.	10,780 – 11,280 μm	Temperatura de superfície Temperatura das nuvens
32.	11,770 – 12,270 μm	
33.	13,185 – 13,485 μm	Altitude de topo de nuvens
34.	13,485 – 13,785 μm	
35.	13,785 – 14,085 μm	
36.	14,085 – 14,385 μm	

FONTE: (JONATHAN, 2005)

Esse sensor possui uma resolução temporal diária ao norte da latitude 30° e de dois dias para latitudes inferiores a 30°. Com relação à resolução espacial, esse sensor apresenta as bandas do vermelho e infravermelho próximo, bandas responsáveis pelo cálculo do NDVI, com uma resolução de 250m, as bandas de 3 a 7 com resolução de 500m e as demais bandas do sensor possuem uma resolução de 1000m.

Um fator relevante é a disponibilização de informações relatando a qualidade de cada *pixel* obtido em seus arquivos, propiciando ao usuário o conhecimento das condições em que cada pixel foi adquirido e, por conseguinte determinar o grau de confiabilidade das informações obtidas do pixel em questão. Outra característica muito interessante é a política de distribuição de seus dados de forma gratuita, tornando-o um produto bem atraente para uma grande variedade de usuários.

Em virtude da NASA adotar uma abordagem complexa no concernente a padronização e validação dos seus dados, inclusive com algoritmos para diversas correções como: georreferenciamento e calibração radiométrica, a distribuição dos dados deste sensor não se limita a simples valores de radiância captados pelo sensor.

Desta forma, são distribuídas uma série de produtos que seguem regras de formatação e padronização específicas. Esses produtos são divididos de acordo com seus diferentes níveis de processamento, possibilitando o conhecimento das características gerais de um determinado produto, relacionando-o ao seu respectivo nível de processamento, já que produtos de um mesmo nível compartilham características semelhantes.

Assim sendo, os produtos derivados do sensor MODIS são divididos em cinco níveis. O Nível 0 contem dados brutos, não estando disponível para o usuário. Os produtos do Nível 1A embutem correções para as distorções resultantes dos processos de comunicação e sincronização, já vindo acompanhados de metadados relatando a qualidade de cada pixel. Valores brutos de radiância e dados de localizações geográficas são exemplos de produtos desse nível. Os produtos do Nível 1B são dados do Nível 1A processados com algoritmo de correção radiométrica, seguidos da informação de geolocalização. O Nível 2 é composto de variáveis geofísicas oriundas do nível 1B, são exemplos de produtos deste nível a temperatura na superfície do mar, a estimativa de conteúdo de vapor d' água na coluna de ar e valores de refletância da superfície terrestre. Os produtos do Nível 2G são derivados de dados do Nível 2 reorganizados em uma grade fixa com ladrilhos de dimensões iguais a 1200Km X 1200Km, georreferenciados de forma idêntica. O Nível 3 compõe-se de produtos originados do Nível 2 mapeados em escalas uniformes de tempo e espaço, adicionados de processamento, de modo a torná-los mais consistentes, composições de 16 dias de

índices de vegetação são exemplos de produtos deste nível. Os produtos do Nível 4 são obtidos através de tratamentos complexos de dados de níveis mais baixos tendo como exemplos: dados semanais de índice de área foliar e dados semanais de produtividade primária líquida sobre os oceanos.

2.2.1 Produto MOD13Q1

O produto MOD13Q1 é uma composição de 16 dias de índices de vegetação com uma resolução de 250m correspondente ao Nível 3, segundo a classificação dos produtos do sensor MODIS.

A Tabela 2.2 relaciona as principais características do produto MOD13Q1.

Tabela 2.2 Características do Produto MOD13Q1

Cobertura Temporal	24 ,fevereiro de 2000 -
Área	~10 x 10 lat/long
Tamanho do arquivo	~ 5–270 MB
Projeção	Sinusoidal
Formato de dados	HDF-EOS
Dimensão	4800 x 4800
Resolução	250m
Camada de dados (SDS HDF)	12

FONTE: Adaptado (DAAC, 2006)

Esse produto é obtido através de dados diários de refletância da superfície terrestre, processando-os a fim de identificar a medição mais confiável para cada pixel em um período de 16 dias, levando em consideração as condições atmosféricas e a qualidade angular da observação. São computados dois índices de vegetação: o NDVI, um dos mais utilizados, e o EVI.

Na Figura 2.4 podemos observar o NDVI na superfície terrestre.



Figura 2.4 NDVI na Superfície Terrestre

FONTE: Adaptado (EOS, 2008)

O EVI é um índice específico deste produto, que se utiliza de informações adicionais da região do azul, sendo desenvolvido com o objetivo de minimizar os efeitos da interferência atmosférica, de diferentes tipos de solo e de evitar a saturação de valores do índice em áreas de vegetação mais rigorosa.

O produto MOD13Q1 embute em seus metadados as seguintes informações: qualidade NDVI que possui informações sobre a confiabilidade referente à aquisição de cada *pixel*, qualidade EVI relatando as mesmas informações que a qualidade NDVI, mas com relação ao EVI, Ângulo de Visada que indica o ângulo de visada referente à medição selecionada, Ângulo Solar indicando o ângulo solar para a medição selecionada, Azimute Relativo que indica o ângulo de azimute relativo entre a direção do satélite e a direção do sol. Os dados que compõem este produto são divididos em camadas.

Este produto pode ser obtido gratuitamente através do portal EOS data Gateway [EOS].

2.3 Pré-processamento

Entende-se por pré-processamento o conjunto de procedimentos aplicados sobre os dados de interesse, com o objetivo de prepará-los para análise. Várias técnicas estão disponíveis para esta finalidade. A definição das mais apropriadas depende do objetivo da análise e das características dos dados a serem interpretados.

As técnicas mais usadas são:

- Correção Radiométrica , que objetiva minimizar as diferenças entre os níveis de cinzas registrados por uma matriz de detectores, decorrentes de problemas na calibração dos detectores ou da não linearidade da resposta dos detectores à radiância de uma determinada cena;
- Correção Geométrica, correspondendo à reorganização dos pontos da imagem em relação a um determinado sistema de projeção cartográfica, através de técnicas de reamostragem dos pontos como: vizinho mais próximo, interpolação bi linear e convolução cúbica;

- Correção Atmosférica, objetivando a redução dos efeitos da atmosfera sobre os níveis de cinza de uma determinada cena;
- Manipulação de Contraste, que consiste no ajuste dos níveis de cinza, através da análise do histograma, com objetivo de aumentar a nitidez da imagem;
- Filtragem Espacial, que são transformações realizadas em cada ponto da imagem, levando em consideração a respectiva vizinhança destes pontos. Os filtros podem ser passa-baixa, que atenua os efeitos dos ruídos, ou passa-alta, que realça as regiões de transição de uma cena, como, por exemplo, os limites de áreas culturas diferentes, em imagens de sensoriamento remoto;
- Suavização de Curvas, tendo como finalidade a redução do ruído residual e a facilitação da interpretação dos dados de interesse. Essa suavização é obtida através da aplicação de funções polinomiais de um determinado grau aos dados em análise. O tipo de função e grau a serem aplicados, devem ser determinados de acordo com as dimensões e características dos dados.

2.4 Transformada *Wavelet*

Wavelets (ACHARYA; RAY, 2005) são funções matemáticas que representam um pulso de onda ou pedaço de onda, com energia finita. Uma função *wavelet* ainda possui características oscilatórias de onda, mas tem duração limitada e um valor médio de zero. Estas funções foram desenvolvidas com base na matemática, física quântica e estatística. São funções que decompõem os sinais em diferentes componentes de frequência e analisam cada componente em diferentes resoluções, mantendo a informação temporal.

Uma função para ser considerada *wavelet* ($\psi(t)$) deve possuir as seguintes características:

- i. A área total sob a curva da função deve ser zero; ou seja;

$$\int_{-\infty}^{\infty} \psi(t) dt = 0$$

- ii. A energia da função deve ser finita; ou seja; $\int_{-\infty}^{\infty} |\psi(t)|^2 dt < \infty$

As funções *wavelets* são geradas de uma função base, conhecida como *wavelet* mãe, pelos processos de dilatação (escala) e deslocamento no domínio do tempo. As *wavelets* originadas por determinada função *wavelet* base podem ser representadas pela seguinte formula:

$$\psi_{a,b} = \frac{1}{\sqrt{|a|}} \psi\left(\frac{t-b}{a}\right)$$

Onde:

a e b – números reais, representando a dilatação e o deslocamento no eixo do tempo.

ψ – função *wavelet* base.

Como exemplos de funções *wavelet* básicas pode-se citar: a *wavelet* de Haar (DAUBECHIES, 1992; MALLAT, 1989), a família de *wavelet* de Daubechies (DAUBECHIES, 1992), a função de Morlet (COUPINOT; HECQUET; AURI`ERE *et al.*, 1992; GOUPILLAUD; GROSSMANN; MORLET, 1985) e a curva conhecida como chapéu mexicano (STARCK; MURTAGH; BIJAOU, 1998).

A *wavelet* de Haar é a mais simples e provavelmente a mais antiga das *wavelets*, sendo representada graficamente por um pulso quadrado (Figura 2.5), definido por:

$$\psi(t) = \begin{cases} 1 & 0 \leq t < 0.5. \\ -1 & 0.5 \leq t < 1. \\ 0 & \text{para outros valores de } t. \end{cases}$$

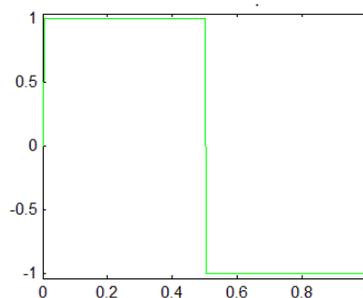


Figura 2.5 Wavelet Haar

As *wavelets* da família de Daubechies são conhecidas por dbN, onde N é a ordem da função desejada. A função de ordem 1 (db1) é similar a função de Haar. Na Figura 2.6 observam-se alguns exemplos desta família.

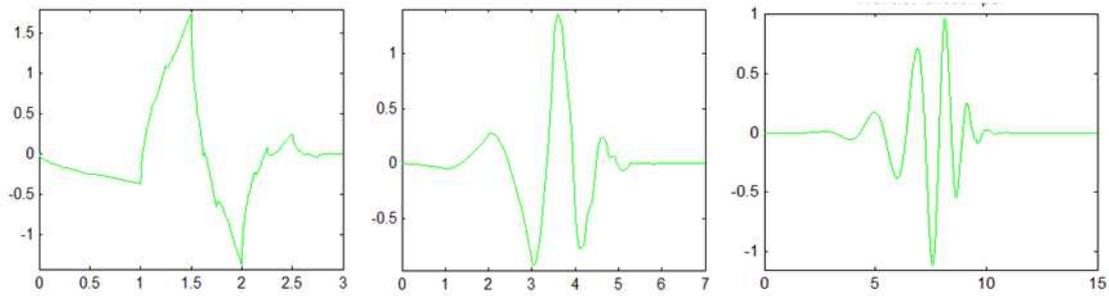


Figura 2.6 Wavelet de Daubechies (db2, db4,db8) da esquerda para a direita.

A função de Morlet (Figura 2.7) se expressa matematicamente através da fórmula:

$$\psi(t) = e^{-t^2} \cos\left(\pi t \sqrt{\frac{2}{\ln 2}}\right)$$

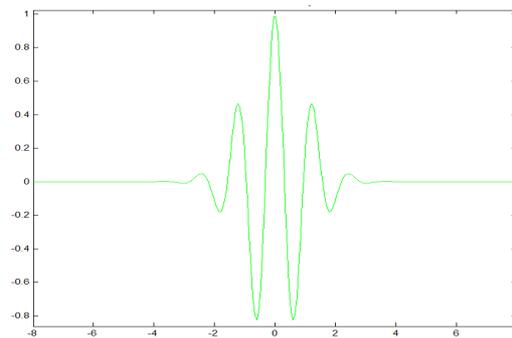


Figura 2.7 Wavelet de Morlet

A curva chapéu mexicano (Figura 2.8) deriva-se da função gaussiana $-0.5e^{-t^2}$, sendo representada pela equação:

$$\psi(t) = (1 - 2t^2)e^{-t^2}$$

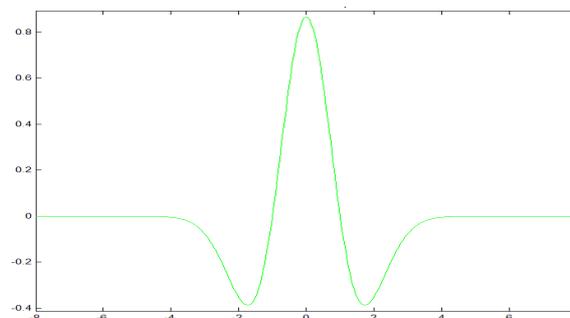


Figura 2.8 A Curva Chapéu Mexicano

As Funções *wavelets* são utilizadas para analisar outras funções unidimensionais ou multidimensionais da mesma forma que a Transformada de Fourier (WALKER, 1988) utiliza as funções seno e coseno. A análise de Fourier representa um determinado sinal em um conjunto de senoides de diferentes frequências, representando matematicamente a transformação de um sinal no domínio do tempo para o domínio da frequência.

Embora esta transformada seja bastante útil em muitas aplicações, possui uma limitação quando a análise temporal se faz necessária, ou seja, quando é preciso se determinar o tempo da ocorrência de um determinado evento, pois no processo de passagem do tempo para a frequência, esta informação se perde. A Figura 2.9 representa a transformada de Fourier, percebe-se a impossibilidade da determinação do momento da ocorrência dos eventos no domínio da frequência.



Figura 2.9 Transformada de Fourier

FONTE: Adaptado de (MISITI; MISITI; OPPENHEIM *et al.*, 2002)

Para sinais transitórios, certas características como mudanças bruscas e início ou término de eventos, que geralmente são partes importantes do sinal, não são detectadas pela transformada de Fourier. Para estes tipos de sinais, a Transformada *Wavelet* possibilita a detecção e análise destas ocorrências.

Similarmente à Transformada de Fourier que utiliza as funções seno e coseno, a análise *wavelet* consiste em decompor uma função complexa em versões da *wavelet* original (mãe) onde foram mudados os fatores de escala e de translação. A diferença consiste no fato das *wavelets* possuírem suporte compacto, energia finita e, principalmente, serem capazes de detectar e localizar a ocorrência de altas e baixas frequências, preservando a informação de tempo do sinal original.

A Transformada *Wavelet* é uma ferramenta matemática que permite decompor e descrever um sinal em diferentes escalas, gerando uma pirâmide em múltiplas resoluções. Nessa transformação, o sinal original passa a ser expresso por coeficientes que representam os componentes de alta e de baixa frequência presentes no sinal.

A Transformada *Wavelet* possibilita a obtenção dos coeficientes da transformação em várias resoluções e a reconstituição do sinal original através do inverso da Transformada. Assim sendo, a análise *wavelet* permite representar um sinal como um conjunto de coeficientes dados pelo produto interno da função original com uma função elementar de energia finita (*wavelet*).

A Transformada *Wavelet* pode se expressar matematicamente através da seguinte equação:

$$W(a, b) = \int_{-\infty}^{\infty} f(t) \frac{1}{\sqrt{|a|}} \psi^* \left(\frac{t-b}{a} \right) dt.$$

onde:

a e b – representam a dilatação e translação.

A forma de recompor o sinal no domínio do tempo a partir de sua decomposição é através da transformada inversa, que se representa pela formula:

$$f(t) = \frac{1}{C} \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} \frac{1}{|a|^2} W(a, b) \psi_{a,b}(t) da db;$$

onde:

$$C = \int_{-\infty}^{\infty} \frac{|\psi(\omega)|^2}{|\omega|} d\omega.$$

a e b – representam a dilatação e a translação.

A análise *wavelet* é realizada através da aplicação sucessiva da Transformada *Wavelet*, atribuindo-se diversos valores para *a* e *b*, representando a decomposição do sinal original em diversos componentes localizados no tempo e na frequência, de acordo com estes parâmetros.

São definidos dois tipos de Transformada *Wavelet*: contínua e discreta.

A Transformada *Wavelet* contínua é definida como a soma em todo o tempo do sinal original multiplicado pelas versões escalonadas e deslocadas da função *wavelet* base. Através da formula original da Transformada *Wavelet*, pode-se representar a transformada contínua pela seguinte equação:

$$C(a, b) = \int_{-\infty}^{\infty} f(t)\psi(a, b, t)dt$$

onde:

ψ - função *wavelet* base.

a – escala.

b – posição.

O resultado dessa transformação é expresso através de coeficientes, que são funções da escala e posição. Multiplicando cada coeficiente pela sua respectiva *wavelet* escalonada e deslocada, obtêm-se as *wavelets* constituintes do sinal original.

A transformada discreta decompõe o sinal original em diferentes bandas de forma que as bandas de freqüências mais baixas possuam uma resolução melhor no domínio da freqüência e uma menor resolução temporal, comparativamente com as bandas de freqüência mais altas. Nesse tipo de transformada as variações do fator de escala e de translação no tempo são discretas, sendo estas variações do tipo $a = 2^j$, onde j é o nível da decomposição e a o fator de escala, eliminando desta forma, parte da redundância relacionada à Transformada *Wavelet* contínua. Uma forma de se representar a Transformada *Wavelet* discreta é através de filtros espelhados dos tipos passa baixa e passa alta (STRANG; NGUYEN, 1996). A Figura 2.10 ilustra os processos de análise e reconstrução com o uso desta tecnologia. No processo de decomposição os sinais originais passam por filtros passa alta (H) e passa baixa (L), em seguida são selecionadas as amostras de índices pares dos coeficientes, resultando nos coeficientes de detalhes (cD) e coeficientes de aproximação (cA). Note que os detalhes resultam das freqüências altas. No processo de reconstrução o procedimento inverso é aplicado aos coeficientes da Transformada *Wavelet*, recompondo, desta forma, os sinais originais.

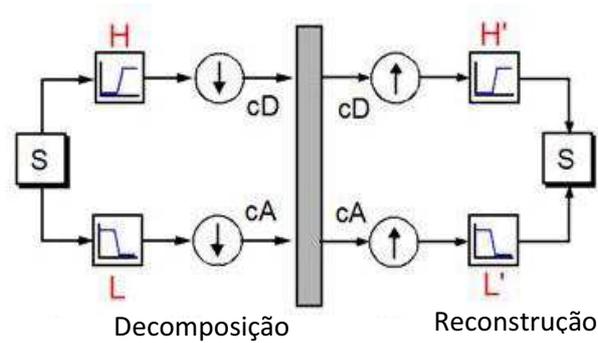


Figura 2.10 Transformada Wavelet com Uso de Filtros

FONTE: Adaptado de (MISITI; MISITI; OPPENHEIM *et al.*, 2002)

2.5 Redes Neurais

As Redes Neurais (HAYKIN, 2001) representam uma tecnologia que têm base em muitas disciplinas: neurociência, matemática, estatística, física, ciência da computação e engenharia. Na sua forma mais geral, rede neural é uma máquina projetada para modelar a maneira como o cérebro realiza uma tarefa particular ou função de interesse (KOVÁCS, 1997). Desta forma as Redes Neurais Artificiais (RNA) constituem-se em um paradigma computacional baseado no modelo biológico do cérebro humano, representado através de um conjunto de elementos de processamento muito simples (atuando como neurônios), altamente conectados e processando em paralelo. Estas unidades são dispostas em uma ou mais camadas e interligadas por um grande número de conexões, geralmente unidirecionais. Na maioria dos modelos estas conexões estão associadas a pesos, os quais armazenam o conhecimento representado no modelo e servem para ponderar a entrada recebida por cada neurônio da rede (BRAGA; CARVALHO; LUDERMIR, 2000).

As Redes Neurais apresentam como principais características e atrativos: a Aprendizagem e a Generalização. A Aprendizagem é capacidade de uma rede aprender a resolver um determinado problema através de amostras de treinamento e Generalização é a condição de poder generalizar esta aprendizagem realizada por um número pequeno de amostras, estendendo-a para dados não conhecidos. Uma rede neural não é programada e sim treinada para a solução de um problema específico. Outras características inerentes as Redes Neurais são: capacidade de extrair

informações não explicitamente representadas pelas amostras, serem capazes de mapear funções multivariáveis com custo computacional crescendo apenas linearmente com o número de variáveis, reconhecer e classificar padrões, auto-organização e processamento temporal.

Estas características fazem das Redes Neurais uma ferramenta computacional bastante interessante para resolução de problemas complexos, difíceis de serem resolvidos por abordagens tradicionais, desde que sejam levadas em consideração algumas limitações desta tecnologia como: soluções aproximadas e não exatas que podem ou não estar corretas e não serem aplicáveis a qualquer problema.

As Redes Neurais são baseadas em modelos de neurônios artificiais. Estes neurônios compõem-se estritamente de conexões e pesos de entrada emulando os dendritos e sinapses de uma função de mapeamento simulando o corpo celular e uma saída realizando as funções do axônio, conforme exemplificado na Figura 2.11

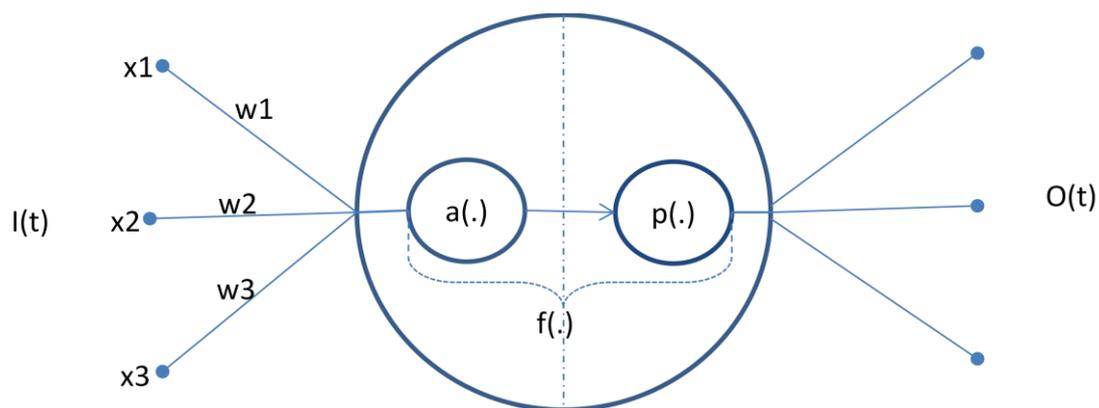


Figura 2.11 Modelo Genérico de Neurônio Artificial

As entradas $I(t)$ representam os estímulos que chegam ao neurônio num determinado instante de tempo, enquanto que os pesos (w) representam as sinapses que ponderam os estímulos a serem processados pelo corpo celular.

A função de transferência ($f(.)$) geralmente se compõe de duas outras funções, a de ativação ($a(.)$) e a de propagação ($p(.)$). A função de ativação é aplicada sobre os sinais de entrada e processa os estímulos ponderados pelos respectivos pesos (sinapses), o que gera uma saída intermediária, que estabelece o estado de ativação do neurônio e sua capacidade de disparar algum sinal de excitação ou de inibição para os neurônios à sua frente. Os pesos, na maioria das arquiteturas de rede hoje propostas, são ajustáveis e representam a memória e o conhecimento usado na

solução do problema. A função de propagação (limiar lógico) é quem define e envia para fora do neurônio o valor do estímulo a ser passado adiante, para os próximos neurônios da rede.

As funções de ativação mais utilizadas são:

- i. Linear (utilizada em 99% dos casos):

$$a_i(\underline{x}, \underline{w}) = \underline{w}^T \underline{x} = \sum_{j=1}^n w_{ij} x_j$$

- ii. Esférica

$$a_i(\underline{x}, \underline{w}) = \rho^{-2} \sum_{j=1}^n (x_j - w_{ij})^2$$

- iii. Mahalanobis

$$a_i(\underline{x}, \underline{w}) = (\underline{x} - \underline{w}_i)^T \Omega^{-1} (\underline{x} - \underline{w}_i)$$

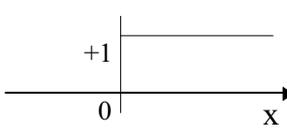
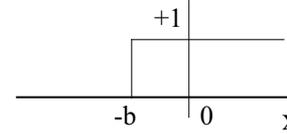
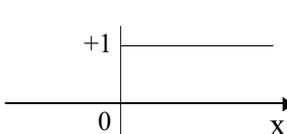
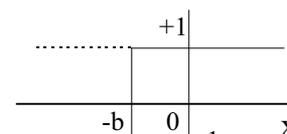
$$\Omega = \underline{X} \underline{X}^T$$

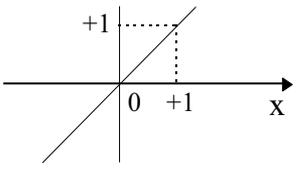
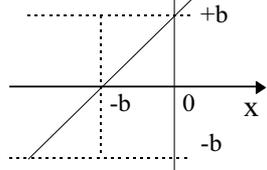
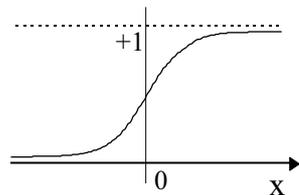
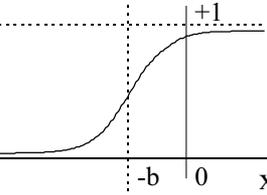
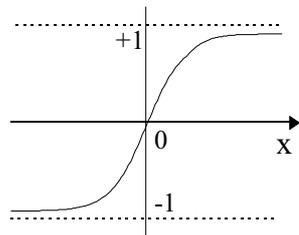
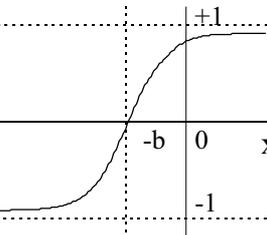
- iv. Polinomial

$$a_i(\underline{x}, \underline{w}) = \sum_{j=1}^n x_j^{w_{ij}}$$

Quanto às funções de propagação, a Tabela 2.3 relaciona as mais usuais.

Tabela 2.3 Funções de Propagação

Função	Equação com Polarização	Sem polarização	Com polarização
Degrau	$y = \begin{cases} 1, & x > -b \\ 0, & x < -b \end{cases}$		
Degrau Simétrico	$y = \begin{cases} 1, & x > -b \\ -1, & x < -b \end{cases}$		

Linear	$y = x + b$		
Logística Sigmoidal	$y = \frac{1}{1+e^{-(n+b)}}$		
Tangente Sigmoidal	$y = \frac{e^{(x+b)} - e^{-(x+b)}}{e^{(x+b)} + e^{-(x+b)}}$		

A função degrau limita a saída do neurônio a apenas dois valores (0 ou 1), sendo normalmente utilizada para criar neurônios que tomem decisões binárias, como nos classificadores. Esta função é limitada, porém não é derivável.

A função linear não é limitada, sendo geralmente utilizada em neurônios com a característica de aproximadores lineares.

A função sigmoidal (logística) permite que a entrada assuma qualquer valor no intervalo $(-\infty \text{ e } \infty)$ e os comprime para o intervalo $[0, +1]$. É a função usualmente adotada em Redes Neurais, em razão de ser contínua, monotônica, não linear e facilmente diferenciável em qualquer ponto.

Após o processamento dos estímulos de entradas, pela função de ativação, o resultado deste processamento é passado para a função de propagação que produz o valor de saída do neurônio.

Algumas vantagens das Redes Neurais são: capacidade de aprendizado, paralelismo, armazenamento do conhecimento de forma distribuída em seus pesos,

maior tolerância a falhas que os algoritmos convencionais, armazenamento associativo da informação, e maior robustez em relação a padrões ruidosos.

As principais desvantagens são: aquisição de conhecimento somente através de aprendizado, impossibilidade de se analisar o procedimento encontrado para a solução, dificuldade de dedução lógica e lentidão do aprendizado.

2.5.1 Arquitetura

A definição da arquitetura de uma rede neural é uma parte importante no seu projeto, já que limita o tipo de problema que pode ser abordado por esta rede.

Entretanto devido à inexistência de um procedimento determinístico para sua estruturação, os parâmetros que formam a arquitetura de uma rede são obtidos heurísticamente. Os seguintes parâmetros compõem a definição da arquitetura de uma rede: número de camadas, número de neurônios em cada camada, tipo de conexão entre os neurônios e topologia da rede.

A organização de uma rede é geralmente realizada em camadas, desta forma, é possível a obtenção de redes de uma única camada, na qual um único neurônio separa uma entrada de uma saída, ou com várias camadas, onde dois ou mais neurônios separam as entradas de suas respectivas saídas. O aumento do número de camadas resulta no aumento da complexidade e do tempo de processamento da rede. Na Figura 2.12 podemos observar: acima o exemplo de uma arquitetura de camada única e abaixo a topologia de uma rede com três camadas.

O incremento do número de neurônios por camada redundante no aumento do grau de liberdade da função de transferência, e quanto maior a quantidade de variáveis livres, menor será a capacidade de generalização da rede. Uma grande quantidade de neurônios pode levar a rede a memorizar os dados de treinamento (*overfitting*), ao invés de extrair as características gerais que permitirão a generalização, por outro lado, um número muito pequeno pode forçar a rede a gastar tempo em excesso na busca de uma solução ótima. Assim, o objetivo de projeto deve ser o de resolver o problema com a menor topologia possível.

pode ser direta ou indiretamente retroalimentado pela sua saída), conexões entre os elementos de processamento de uma mesma camada (estímulos laterais), das camadas anteriores e das camadas posteriores, inexistência de um sentido único para o fluxo dos sinais entre neurônios ou entre camadas; são características da topologia recorrente (Figura 2.14).

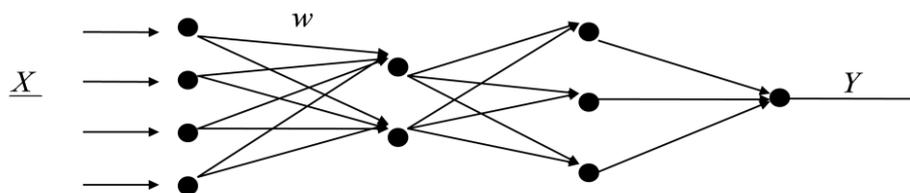


Figura 2.13 Topologia Unidirecional

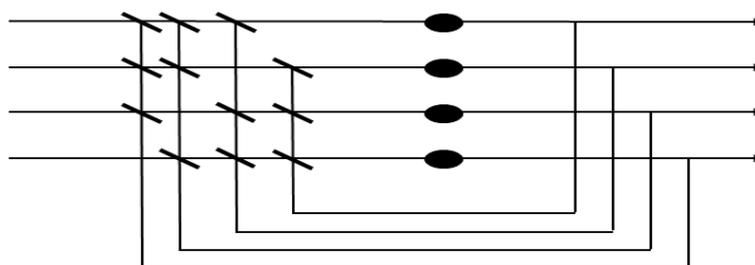


Figura 2.14 Topologia Recorrente

2.5.2 Aprendizado

As Redes Neurais são capazes de aprender através de amostras e de generalizar esse conhecimento de um determinado problema. O paradigma conexionista não se preocupa com obtenção de regras, mas em determinar a intensidade de conexões entre neurônios. Denomina-se algoritmo de aprendizagem o conjunto de procedimentos formalmente definidos para ajustar os pesos de uma rede em busca de uma solução para um problema específico. O processo de aprendizagem caracteriza-se por uma seqüência de eventos interativos, onde inicialmente, a rede recebe estímulos externos (ambiente); em seguida como resultado destes estímulos os parâmetros livres da rede (pesos e fator de polaridade) são reajustados; e, finalmente, devido às alterações ocorridas em sua estrutura interna, a rede responde de uma nova maneira ao ambiente.

Os diversos métodos de treinamento são basicamente divididos em dois paradigmas principais: aprendizado supervisionado e aprendizado não supervisionado.

Os paradigmas aprendizado por reforço e aprendizado por competição, que são variações dos aprendizados: supervisionado e não supervisionado respectivamente, também são bastante conhecidos.

No aprendizado supervisionado as entradas e saídas são relacionadas entre si por um supervisor externo de forma que, para cada padrão de entrada é especificado um padrão de saída desejado. Esse tipo de aprendizado tem a desvantagem de não ser capaz de aprender novas estratégias para situações não incluídas nos exemplos de treinamento, na ausência do supervisor.

Existem basicamente duas formas de se executar o aprendizado supervisionado: estática e dinâmica. No treinamento estático, os dados do conjunto de treinamento permanecem imutáveis, de forma que, obtida uma solução esta deve permanecer fixa. Assim, necessita de um novo treinamento de todo conjunto de dados no caso de novas informações serem adicionadas a base de treinamento. Já no treinamento dinâmico, a rede está em constante processo de adaptação as contínuas alterações do conjunto de dados.

Por outro lado, o aprendizado não supervisionado se caracteriza pela ausência de um supervisor para acompanhar o processo de treinamento, de modo que, não existe uma relação entre entradas e saídas determinada por um supervisor, ou seja, somente as entradas são utilizadas no processo de treinamento. Estas entradas são processadas pela rede que se organiza de modo a agrupá-las segundo algum critério de similaridade. Neste tipo de rede os neurônios são utilizados como formadores de categorias.

O aprendizado por reforço consiste em mapear as entradas e saídas através de um processo de triagem com a finalidade de maximizar o índice de desempenho escalar (sinal de reforço).

O aprendizado por competição estabelece uma disputa entre as unidades de saída para definir qual delas será ativada e conseqüentemente terá seus pesos atualizados.

Os algoritmos de aprendizado estão relacionados aos parâmetros de aprendizado: taxa de aprendizado (*learning rate*), momento (*momentum*), condição de parada e dinâmica de treinamento.

A taxa de aprendizado controla a intensidade com que os pesos da rede serão atualizados. É um valor positivo normalmente menor que 1.0, sendo que taxas muito altas, próximas de 1.0 podem causar instabilidade na rede, inclusive impedindo-a de obter um patamar aceitável de aprendizado. Por outro lado valores muito baixos, próximos de zero, podem tornar o aprendizado muito lento. Não é necessário que o valor da taxa de aprendizado permaneça constante durante todo o treinamento, podendo ser adaptativa e controlada pela própria rede em alguns casos.

O momento é um parâmetro que visa possibilitar a eliminação dos mínimos locais durante a busca dos mínimos globais (erro mínimo). É um valor positivo, menor que 1.0 e de uso opcional.

A condição de parada determina um evento para o termino do treinamento. Esta de forma geral, se baseia em dois eventos: erro mínimo, que encerra o treinamento quando a rede converge para um valor de erro menor que o estipulado para o critério de termino, e numero de ciclo de treinamento, que termina o processo de forma independente do nível de aprendizado alcançado pela rede e deve ser usado conjuntamente com outro critério a fim de evitar processos de treinamento intermináveis.

A dinâmica de treinamento define a freqüência de ajuste dos pesos da rede, podendo ser de dois tipos: lote e incremental. No tipo lote, os parâmetros são ajustados no final de cada ciclo (processamento de todo o conjunto de observações), diminuindo a influencia da ordem de apresentação dos padrões e reduzindo a sensibilidade a instabilidades, porém torna a convergência da rede mais lenta. No tipo incremental, os parâmetros da rede são ajustados a cada observação e a ordem de apresentação dos padrões afeta a velocidade de aprendizado, devendo em alguns casos ser reorganizada a fim de acelerar o treinamento.

2.5.3 Mapa Auto Organizável de Kohonen

O Mapa Auto-Organizável (SOM) é uma arquitetura de rede neural, com aprendizado do tipo não-supervisionado, podendo ser considerado uma extensão do modelo competitivo, distinguindo-se por considerar a região de vizinhança entre os neurônios, organizando as saídas em uma forma geométrica definida. Desta forma, as redes SOMs aprendem não somente a distribuição, como nos modelos competitivos, mas também a topologia dos vetores de entrada. Esse modelo se baseia no fato de, no cérebro humano, as diferentes entradas sensoriais serem mapeadas para áreas correspondentes do córtex cerebral de forma ordenada.

Os fundamentos dos mapas auto-organizáveis tiveram sua origem nos trabalhos de Grosseberg e Von Der Malsburg (GROSSBERG, 1974; VON DER MALSBURG, 1973), visando explicar a formação de mapas topológicos neurais. Posteriormente com base neste estudo, Kohonen (KOHONEN, 1982) propôs um modelo que passou a ser conhecido por Mapa Auto-Organizável de Kohonen.

A arquitetura do mapa auto-organizável de Kohonen (Figura 2.15) compõe-se de uma malha, geralmente uni ou bidimensional, onde todas as unidades possuem conexões com todas as componentes de entrada. Nessa estrutura, um vetor de pesos de mesmas dimensões do vetor de entrada é responsável pela conexão dos componentes da entrada a cada neurônio que compõe a rede. Esse modelo tem a capacidade de projetar dados de dimensões maiores em uma grade de dimensões menores. Essa projeção é realizada de forma adaptativa, mantendo as características topológicas dos dados originais.

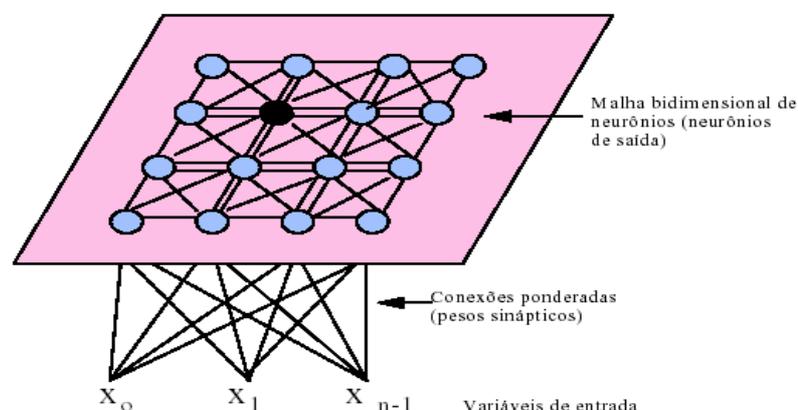


Figura 2.15 Exemplo de Topologia de Mapa de Kohonen

FONTE: (ASSIS)

A aprendizagem é alcançada através da aplicação de um aprendizado competitivo aplicado aos neurônios, onde cada unidade responde seletivamente a um determinado padrão de entrada. Esse processo se inicia com a inicialização de forma aleatória dos pesos sinápticos da grade. Em seguida são executados três processos importantes para a construção do mapa: a competição, a cooperação e a adaptação.

Na competição, os dados de entrada são relacionados com os pesos dos neurônios da grade através de uma função discriminante, declarando-se vencedor a unidade que obtiver o maior valor. Por outro lado, a cooperação se caracteriza pela determinação da região vizinha ao neurônio vencedor. Finalmente, a fase de adaptação é responsável pelo ajuste dos pesos do neurônio vencedor e de seus vizinhos.

Basicamente o algoritmo do mapa de Kohonen possui o seguinte funcionamento:

- i. Escolha aleatória dos pesos sinápticos;
- ii. Apresentação dos padrões de entrada;
- iii. Determinação do neurônio vencedor, ou seja, da unidade que mais se aproxima do valor de entrada apresentado;
- iv. Ajuste dos pesos sinápticos do neurônio vencedor e de todos os outros que se encontram dentro de sua vizinhança. Estes ajustes são realizados pela seguinte regra de aprendizado:

$$w_w(t + 1) = w_j(t) + \eta(t)h_{jv}(t) [x(t) - w_j[t]]; \text{ onde}$$

h_{jv} – função de vizinhança

$\eta(t)$ – taxa de aprendizado no instante t ; $0 < \eta(t) < 1$

- v. Repetir a partir do item ii, até que não haja mais mudanças sensíveis dentro do mapa de características.

A função de vizinhança tem sua largura reduzida ao longo do tempo, e se representa normalmente pela função gaussiana:

$$h_{jv(t)} = \exp\left(\frac{-\|w_v(t) - w_j(t)\|^2}{2\rho^2(t)}\right)$$

onde: $\rho(t)$ - largura;

2.6 Lógica Nebulosa

A lógica clássica é precisa e inflexível. Entretanto, o mundo está repleto de relações imprecisas que não podem ser modeladas por esta lógica. Desta forma a lógica clássica e os sistemas convencionais não são capazes de expressar a inexatidão do mundo real.

A dificuldade da lógica tradicional em estabelecer interpretações para as indefinições do mundo real despertou interesse em pensadores como Bertrand Russel que, em seus estudos, formulou o paradoxo do mentiroso de Creta, que pode ter o seguinte enunciado: *“O Filósofo Cretense dizia que todos os Cretenses mentem”*.

Assim, conclui-se que se ele mente então ele pode falar a verdade e que se ele fala a verdade então ele pode estar mentindo. De modo que, não é possível a representação desta sentença na teoria convencional, pois nesta, não existem meias verdades ou meias mentiras, existindo somente o conceito de falso e verdadeiro. Albert Einstein também retrata este problema ao afirmar que: *“Tanto quanto as leis da Matemática se referem à realidade elas não estão certas. Tanto quanto estas leis estão certas elas não se referem a realidade.”*

A Lógica Nebulosa (D. DRIANKOV; REINFRANK, 1993; LEE., 1990) apresenta-se como um paradigma capaz de modelar as imprecisões do mundo real.

Embora existissem trabalhos anteriores, o estudo do professor Lofty Zadeh (ZADEH, 1965) impulsionou as pesquisas sobre Lógica Nebulosa, que teve seu uso sedimentado pelo trabalho do pesquisador Ebrahim Mamdani (MAMDANI, 1975) ao aplicar a Lógica Nebulosa na criação de um sistema baseado em regras nebulosas.

Diferentemente da teoria clássica, em que a relação de pertinência é bem delineada, de forma, que um elemento pertence ou não pertence a um conjunto, na abordagem nebulosa, essa relação é definida por graus de inclusão, de modo que as fronteiras entre determinados conjuntos não possuem um limiar tão bem caracterizado, sendo possível um elemento pertencer a vários conjuntos de acordo com seus respectivos graus de inclusão; que são valores que variam entre 0 e 1, e são

atribuídos a cada elemento de um conjunto nebuloso. Esses valores são determinados pelas funções de inclusão, que são modelos matemáticos simples, objetivando a determinação do potencial de um elemento pertencer a um determinado conjunto. Essas funções podem ser obtidas por observações de um determinado problema ou pela aquisição de métricas definidas estatisticamente, podendo ser alteradas durante a fase de testes, a fim de melhor refletir uma solução para o problema analisado.

Assim, um conjunto nebuloso (ZIMMERMANN, 2001) pode-se representar por pares ordenados, nos quais define-se o elemento e seu respectivo grau de inclusão:

$$A = \{x, \mu(x)\} / x \in U$$

Onde: U é o domínio considerado;

x é um elemento do conjunto nebuloso;

$\mu(x)$ é a função de inclusão.

A função de inclusão pode ser expressada matematicamente da seguinte forma:

$$\mu(x): U \rightarrow [0,1]$$

As funções de inclusão são de característica unimodal, garantindo, assim, que uma determinada variável somente influenciará o problema de forma local. Uma função de inclusão é considerada unimodal, se for definida da seguinte forma:

$$\forall x_1, x_2 \in X, \forall \lambda \in [0, 1]: \mu(\lambda x_1 + (1 - \lambda)x_2) \geq \min(\mu(x_1), \mu(x_2))$$

As funções de inclusão mais utilizadas são: singular, clássica, linear, triangulares, trapezoidais, sigmóide e beta (CRUZ, 2004).

Como na teoria de conjuntos clássica, os conjuntos nebulosos também possuem conceitos que se diferem da teoria tradicional, por se basearem nas funções de inclusão. Dentre estes conceitos pode-se destacar:

- i. Suporte - definido da seguinte forma:

$$S_A = \{x \in X \mid \mu_{A(x)} > 0\}$$

onde : A é um conjunto .

$\mu_{A(x)}$ é a função de inclusão.

O suporte pode ser compacto (Figura 2.16) quando seu tamanho é menor que o universo de interesse original; e não compacto, podendo neste caso acarretar uma sobrecarga no sistema devido à possibilidade de ativação de várias regras para cada entrada, resultando numa possível perda do armazenamento e recuperação do conhecimento local.

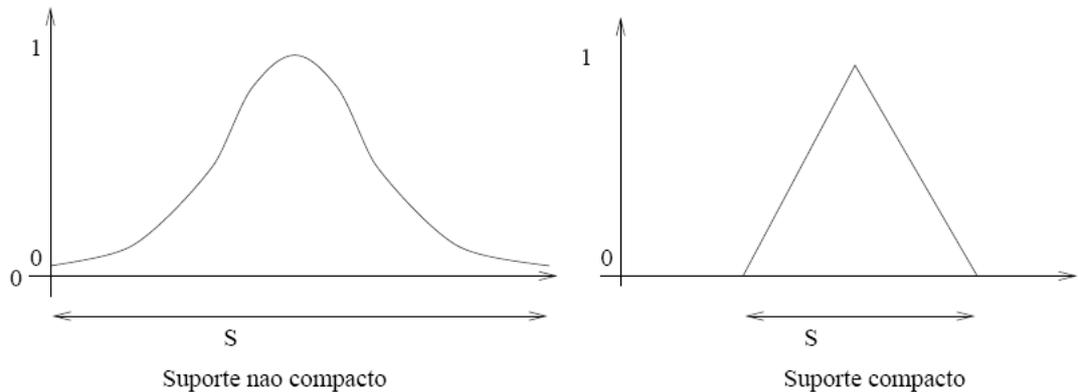


Figura 2.16 Suporte Compacto e Não Compacto

FONTE: (CRUZ, 2004)

- ii. Corte - podendo se expresso como:

$$A_{\alpha} = \{x \in X \mid \mu_A(x) \geq \alpha\}$$

$$A'_{\alpha} = \{x \in X \mid \mu_A(x) > \alpha\}$$

onde: A é um conjunto

$\mu_{A(x)}$ é a função de inclusão;

A_{α} é o conjunto corte;

A'_{α} é denominado conjunto corte forte.

- iii. Cardinalidade - representada pela seguinte equação:

$$|A| = \sum_{x \in X} \mu(x)$$

No caso de cardinalidade relativa temos:

$$\|A\| = \frac{|A|}{|X|}$$

Para conjuntos infinitos, a cardinalidade define-se da seguinte forma:

$$A = \int_x \mu_A(x) dx$$

- iv. Altura - definida como:

$$H_A = \max_{x \in X} \{\mu_A(x)\}$$

- v. Distância – mede a distância (Figura 2.17) entre um determinado valor e a definição ideal do conjunto, sendo definida como:

$$d(A, x) = \begin{cases} \infty & \text{se } \mu_A(x) = 0 \\ \frac{1}{\mu_A(x)} - 1 & \text{se } \mu_A(x) \neq 0 \end{cases}$$

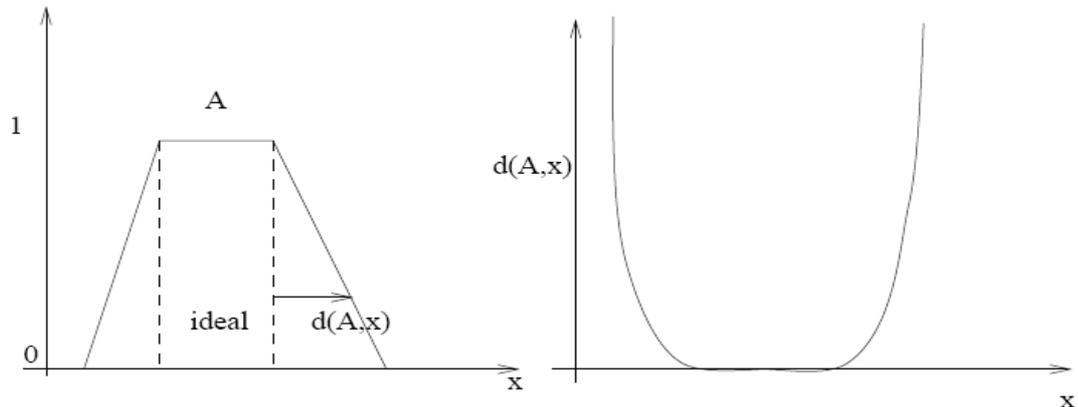


Figura 2.17 Conceito de Distancia

FONTE: (CRUZ, 2004)

Da mesma forma que na teoria clássica, a Lógica Nebulosa também possibilita a realização de operações entre conjuntos através das suas funções de inclusão. A interseção entre conjuntos nebulosos é definida através de uma família de operadores denominada T-norma ou norma triangular e a união por uma família de operadores conhecida como T-conorma ou S-norma. Estes conjuntos de operadores são constituídos de funções com as seguintes características gerais:

- i. Comutatividade: $\nabla(a,b) = \nabla(b,a)$;
 - ii. Associatividade: $\nabla(a, \nabla(b,c)) = \nabla(\nabla(a,b), c)$;
 - iii. Monotonicidade: $\nabla(a,b) \leq \nabla(c,d)$ se $a \leq c$ e $b \leq d$;
- onde: ∇ é uma função e $\forall a, b, c, d \in [0,1]$;

Além destas características gerais, um operador, para ser considerado T-norma deve satisfazer a seguintes condições: $\nabla(0,0) = 0$ e $\nabla(a,1) = \nabla(1,a) = a$; e para ser considerado T-conorma deve atender às regras: $\nabla(1,1) = 1$ e $\nabla(a,0) = \nabla(0,a) = a$. A Tabela 2.4 relaciona as principais T-normas e T-conormas. Assim sendo, a interseção pode ser definida como: $\mu_I(x) = \min(\mu_A(x), \mu_B(x))$, $x \in X$; e a união como:

$\mu_U(x) = \max(\mu_A(x), \mu_B(x))$, $x \in X$, onde: $\mu_I(x)$ e $\mu_U(x)$ são os graus de inclusão do elemento x respectivos a união e interseção e $\mu_A(x)$ e $\mu_B(x)$ são respectivamente os graus de inclusão dos conjuntos A e B.

Outro operador muito utilizado é o de complemento ou negação, que se define como: $\mu_C(x) = 1 - \mu_A(x)$, $x \in X$.

Tabela 2.4 Principais T-Normas e T-Conormas

<i>T-norma</i>	<i>T-conorma</i>	nome
$\min(a, b)$	$\max(a, b)$	Zadeh
$a \cdot b$	$a + b - ab$	probabilista
$\max(a + b - 1, 0)$	$\min(a + b, 1)$	Lukasiewicz
$\begin{cases} a, & \text{se } b = 1 \\ b, & \text{se } a = 1 \\ 0, & \text{senão} \end{cases}$	$\begin{cases} a, & \text{se } b = 0 \\ b, & \text{se } a = 0 \\ 1, & \text{senão} \end{cases}$	Weber

FONTE: (SANDRI; CORREA, 1999)

Estes operadores satisfazem a lei da dualidade de De Morgan, que pode ser enunciada da seguinte forma:

$$\overline{A \cup B} = \overline{A} \cap \overline{B}$$

$$\overline{A \cap B} = \overline{A} \cup \overline{B}$$

onde: A e B são conjuntos.

Outro conceito importante é o de Relação Nebulosa. Em uma Relação Nebulosa, os elementos podem estar relacionados de forma parcial, expressos em conjuntos nebulosos definidos em produtos cartesianos da teoria clássica. Essas relações podem ser representadas através dos valores relacionados e seus respectivos graus de relação, como exemplificada em uma relação binária pela seguinte equação:

$$R = \{(x, y), \mu_R(x, y)\};$$

Um modo de extrapolar esta relação é através do somatório formado pela união de todos os elementos; como na equação:

$$R = \sum_{(x_i, y_i) \in X \times X} \mu_R(x_i, y_i) / (x_i, y_i);$$

No caso de um produto cartesiano contínuo temos:

$$R = \int_{X \times Y} \mu_R(x, y) / (x, y) ;$$

As Relações Nebulosas podem ser compostas entre si, resultando em uma nova relação. Estas composições podem ser realizadas de diferentes modos, sendo que a principal operação nestas é o cálculo do grau de inclusão dos elementos envolvidos nas respectivas relações.

A Lógica Nebulosa diferentemente da abordagem clássica, que se expressa através de valores, se caracteriza pela representação de modelos próximos à forma do homem se expressar, através de variáveis lingüísticas que, como variável, podem assumir um determinado valor lingüístico entre vários outros pertencentes a um conjunto de termos lingüísticos. Formalmente uma variável lingüística se caracteriza pela quintupla $\{X, T(X), U, G, M\}$, onde: X é o conjunto de termos, U o universo de discurso, G uma gramática a fim de gerar os termos $T(X)$ e M o significado dos termos lingüísticos. Um exemplo seria o caso de classificação de alunos em uma sala de aula; neste caso teríamos a variável lingüística $T(X)=\text{alunos}$. O conjunto de termos da variável aluno $X=\{\text{péssimo, fraco, razoável, bom, excelente}\}$. O universo de discurso definido entre 0 e 10 e as regras semânticas para a associação dos significados e funções de inclusão representadas na Figura 2.18.

Variáveis lingüísticas podem conter modificadores que alteram seu valor. Como exemplo de modificadores temos: “muito”, “pouco”, “não muito” e “mais ou menos”.

Os modificadores podem ser definidos matematicamente.

Conectivos como ‘e’ e ‘ou’ também podem estar associados às variáveis lingüísticas e representam respectivamente as operações de interseção e união de conjuntos, podendo representar, de forma lingüisticamente simples, modelos de alta complexidade.

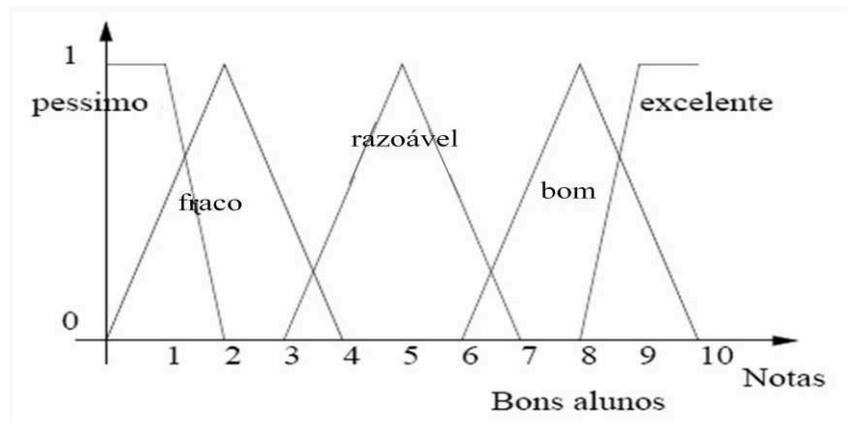


Figura 2.18 Variável linguística relativa ao desempenho de um aluno em relação a sua nota

Uma variável linguística apresenta um número de funções de inclusão, onde cada função representa o valor que um determinado conceito pode assumir, ou seja, os limites que cada função pode ser representada. Esta variável pode ser interpretada como uma função que mapeia o domínio de valores da variável convencional no seu respectivo domínio de valores linguísticos, tornando esta variável em um mecanismo capaz de manipular e quantificar conceitos qualitativos, possibilitando caracterizar as incertezas, as aproximações e as imprecisões em problemas onde as funções não estão bem definidas.

Cada composição dessas variáveis representa uma regra do tipo $A_i \rightarrow B_j$, escrita como: Se x é A_i então y é B_j ; ou Se <Condições> então <Conclusão>.

As condições estão relacionadas aos valores nebulosos linguísticos de uma ou mais variáveis, como exemplo destas condições temos: 'Se nota é baixa então Aluno é fraco'.

A composição de proposições é realizada pelos operadores 'E' e 'OU'.

Quando descreve as condições verificadas pela regra, uma proposição é denominada premissa ou antecedente, e quando descreve a ação determinada por estas condições denomina-se conclusão ou consequência.

A interpretação das regras envolve partes distintas. Inicialmente realiza-se a avaliação do antecedente, a qual envolve a transformação da entrada para nebulosa e a operação dos operadores nebulosos necessários, seguindo-se a aplicação do resultado obtido à sentença de consequência em um processo conhecido como implicação.

Os operadores de implicação mais comumente utilizados são: a função de mínimo, que promove um “corte” no conjunto nebuloso, e a função produto, que resulta em um escalonamento.

Os tipos de regras mais utilizados são: o de Mamdani e o de Takagi e Sugeno (SUGENO, 1985) que se diferencia pelas conclusões serem descritas como expressões não nebulosas.

As funções de pertinência e as regras nebulosas (KLIR; FOLGER, 1988) são utilizadas em sistemas de inferência nebulosos.

Os sistemas de inferência nebulosos se formulam através de um conjunto de regras “se- então”, que mapeiam entradas em saídas. Estas regras traduzem conceitos qualitativos, e noções vagas e imprecisas do mundo real.

A análise de um sistema de inferência nebuloso pode ser dividida em quatro etapas: nebulização das entradas, inferência, agregação e transformação para não nebuloso.

A nebulização consiste em determinar o grau de inclusão de cada entrada em relação aos seus respectivos conjuntos nebulosos através de suas funções de inclusão.

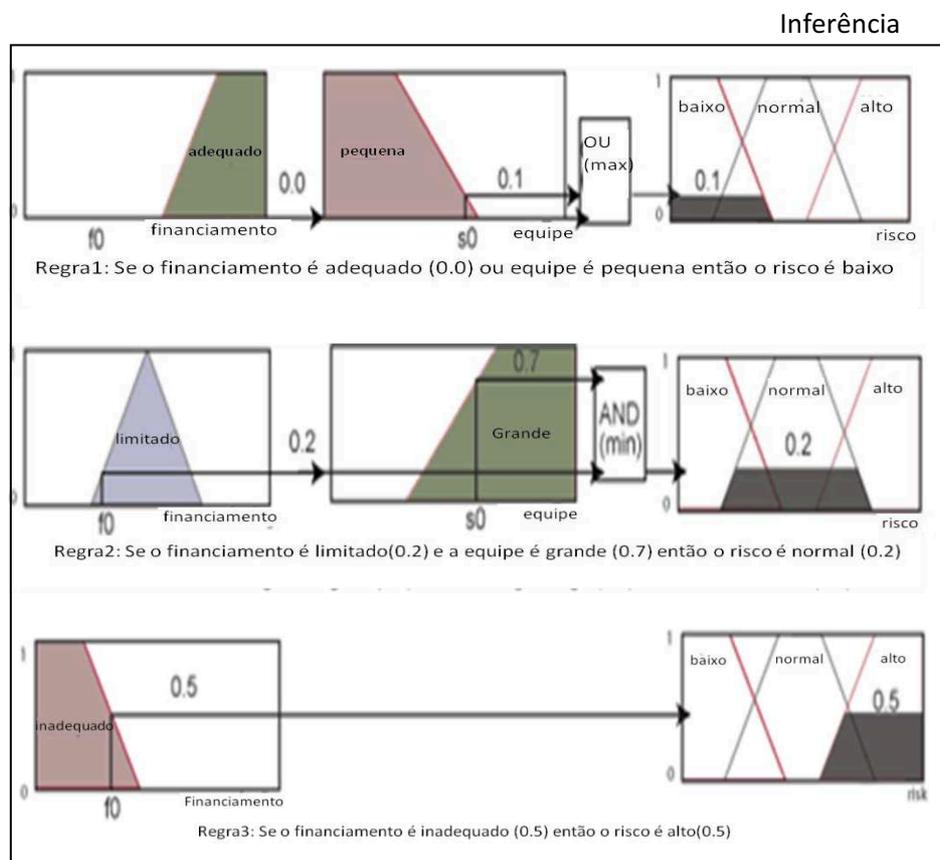
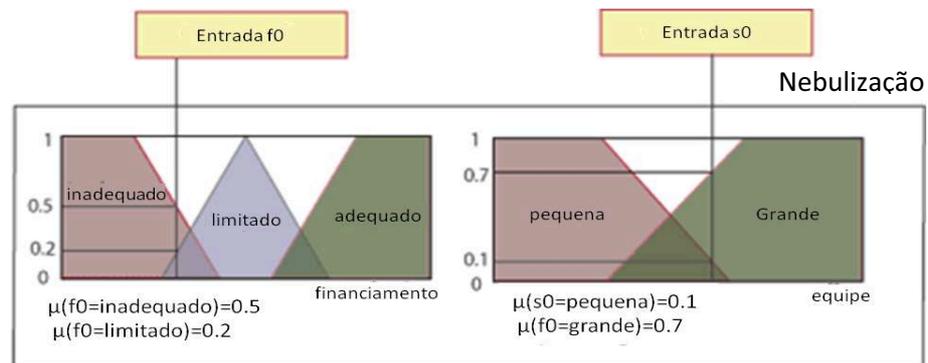
A inferência pode ser dividida em duas partes: a aplicação dos operadores nebulosos sobre os antecedentes de cada regra, representados pelos resultados da nebulização, a fim de se obter um resultado que represente estes antecedentes em um simples valor numérico e a aplicação dos métodos de implicação, que definem o modelo do conjunto nebuloso do conseqüente de cada regra baseado no resultado sobre cada respectivo antecedente obtido pela fase da aplicação dos operadores.

Na agregação, as saídas obtidas para cada regra na fase de inferência são unificadas de forma paralela, obtendo-se um único conjunto nebuloso. A ordem em que as regras são processadas não tem importância, já que os métodos de agregação são comutativos.

Na transformação para não nebuloso o resultado alcançado na etapa de agregação é transformado para um valor não nebuloso, que representa o resultado de uma determinada entrada no domínio do conjunto de saída. Os métodos mais utilizados neste processo são: primeiro máximo, em que o valor de saída é encontrado

através do ponto em que o grau de inclusão atinge o primeiro valor máximo; média dos máximos, definido pelo ponto médio entre os valores que têm maior grau de inclusão, e centro da área, onde o resultado é o centro de gravidade do conjunto resultante da agregação.

A Figura 2.19 mostra as etapas de um sistema de inferência nebuloso através de um exemplo (SYNAPTIC, 2006), que avalia os riscos do desenvolvimento de um projeto, baseado no financiamento e tamanho da equipe disponíveis. As variáveis de entrada são os valores do financiamento e o tamanho da equipe, e a saída é o risco.



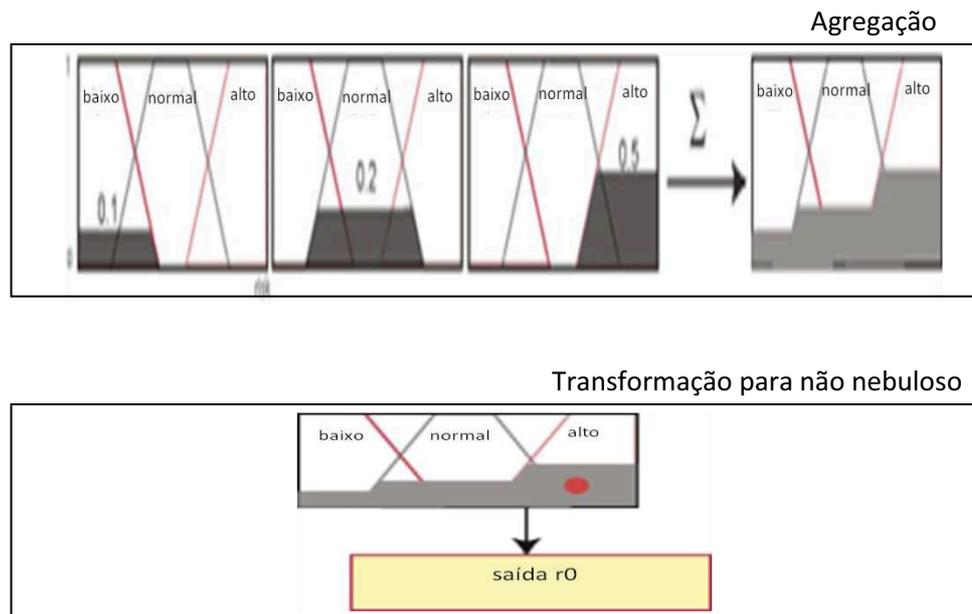


Figura 2.19 Exemplo de Sistema de Inferência Nebuloso

FONTE: Adaptado de (SYNAPTIC, 2006)

As etapas do projeto de um controlador nebuloso (GUERRA, 1998) podem, de forma geral, serem descritas da seguinte maneira:

- i. Definição da arquitetura e das propriedades operacionais como: tipo de controlador, operadores a serem utilizados, sistema de conversão de nebuloso para não nebuloso, etc.;
- ii. Definição dos termos nebulosos para cada variável;
- iii. Descrição das regras que relacionam às variáveis de entrada as propriedades de saída do modelo.

Quanto aos parâmetros, podem ser estruturais, que são fixos, e de sintonização, que variam com o tempo. Os principais parâmetros estruturais são: número de variáveis de entrada e saída, variáveis lingüísticas, funções de pertinência parametrizadas, intervalos de discretização e normalização, estrutura da base de regras, conjunto básico de regras, recursos de operação sobre os dados de entrada. Em relação aos parâmetros de sintonização podemos citar: universo de discurso das variáveis e parâmetros das funções de inclusão.

Podem-se citar como vantagens dos sistemas de inferência, as seguintes características:

- Capacidade de expressar as imprecisões e aproximações do mundo real através de regras;
- Facilidade de entendimento, manutenção e teste;
- Prototipagem em menor tempo;
- Robustez, tolerância a falta de regras ou regras falsas;
- Menor necessidade de regras;
- Avaliação de regras de forma paralela.

Quanto às desvantagens podemos relacionar:

- Necessidade de maior simulação e testes;
- Dificuldade de aprendizagem;
- Dificuldade de estabelecimento correto de regras;
- Ausência de uma definição matemática precisa.

2.7 Sistemas Híbridos (Neuro-Nebulosos)

Os sistemas neuro-nebulosos (LIN; LEE, 1996; NAUCK; KLAWONN; KRUSE, 1997) combinam sistemas nebulosos e Redes Neurais em uma arquitetura que se utiliza dos sistemas nebulosos para representar o conhecimento de uma forma mais simples de se interpretar e a capacidade de aprendizado das Redes Neurais para aperfeiçoar os seus parâmetros. Nesta abordagem, o desconhecimento do comportamento interno de uma rede neural e a dificuldade de se definir as funções de inclusão nos sistemas nebulosos podem ser evitados. Esta combinação se constitui em um modelo interpretável, capaz de usar conhecimentos previamente obtidos.

Basicamente, existem três modelos de sistemas neuro-nebuloso: cooperativo, concorrente e fundido.

No modelo cooperativo, o mecanismo de aprendizado da rede neural determina as funções de inclusão ou as regras nebulosas do sistema nebuloso a partir de dados de treinamento. Geralmente a base das regras é determinada através de uma abordagem por agrupamentos (redes auto-organizáveis) ou algoritmos de agrupamentos (YAGER; FILEV, 1994).

Em um sistema concorrente a rede neural, auxilia continuamente o sistema nebuloso na determinação dos parâmetros necessários à solução de um problema específico.

No modelo fundido, os parâmetros do sistema nebuloso são obtidos através dos algoritmos de aprendizado de rede neural. Uma das arquiteturas bem utilizada deste modelo é o sistema neuro-nebuloso de inferência adaptativo (ANFIS).

2.7.1 Sistema Neuro-Nebuloso de Inferência Adaptativo (ANFIS)

O ANFIS possibilita, através de um conjunto de pares de entradas e saídas (base de treinamento), a construção de um sistema de inferência nebuloso, cujo os parâmetros das funções de inclusão são ajustados pelo uso do algoritmo de Retropropagação isoladamente ou em combinação com o método dos mínimos quadrados. Estes ajustes permitem o sistema nebuloso aprender a partir dos dados de modelagem.

Os parâmetros associados às funções de inclusão se modificam durante o processo de treinamento. A obtenção ou o ajuste destes parâmetros é facilitado pela utilização de um vetor gradiente, que avalia a capacidade do sistema de inferência modelar as entradas e saídas para um determinado conjunto de parâmetros. Quando o vetor gradiente é obtido, qualquer uma das várias rotinas de aperfeiçoamento pode ser aplicada, objetivando o ajuste dos parâmetros e reduzindo alguma medida de erro.

Essa medida de erro é geralmente obtida pela soma dos quadrados das diferenças entre as saídas: atual e desejada.

O ANFIS (JANG) se baseia em um sistema de inferência do tipo Takagi Sugeno e possui uma arquitetura de cinco camadas (Figura 2.20). A primeira camada escondida é responsável pela nebulização das variáveis de entrada. Os operadores T-norma são executados na segunda camada escondida, a fim de tratar as regras da parte antecedente. A terceira camada escondida normaliza a intensidade das regras. Enquanto que, na quarta camada escondida, os parâmetros da parte conseqüente da regra são determinados. A camada de saída executa todas as entradas como o somatório de todos os sinais recebidos.

O ANFIS utiliza o algoritmo de aprendizado de Retropropagação para determinar os parâmetros da parte antecedente (aprender os parâmetros, como forma e posição, relacionados às funções de inclusão) e o método do mínimo quadrado médio para estimar os parâmetros da parte conseqüente, que especificam a saída de cada regra. Um passo no procedimento de aprendizagem tem duas partes.

Na primeira parte, os padrões de entrada são propagados e estimam-se os parâmetros mais adequados da parte conseqüente através de um processo iterativo (mínimo quadrado médio), enquanto que, os parâmetros da parte antecedente são considerados fixos para o corrente ciclo durante o treinamento. Na segunda parte, os padrões são novamente propagados e o algoritmo Retropropagação é usado para modificar os parâmetros da parte antecedente, enquanto que, os parâmetros da parte conseqüente permanecem fixos.

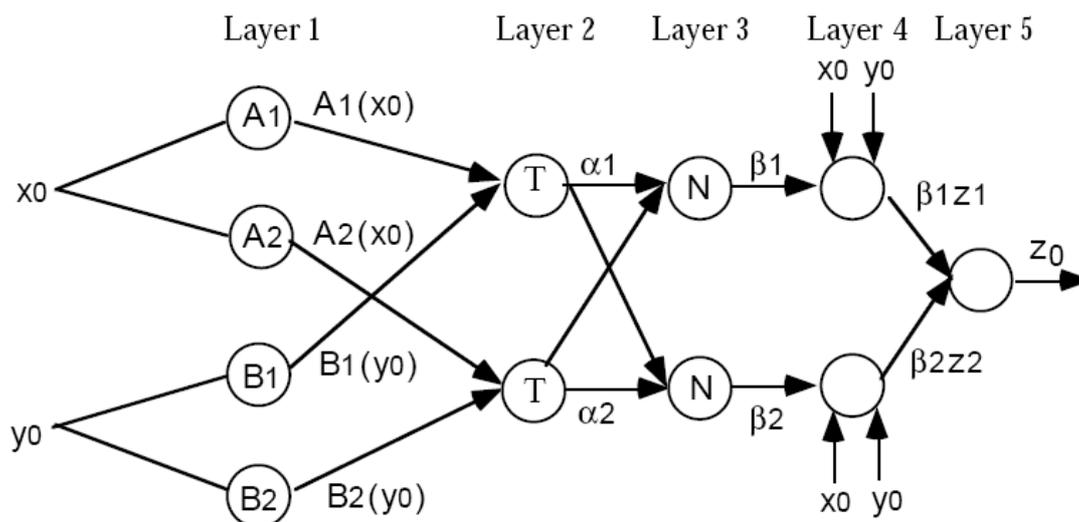


Figura 2.20 Arquitetura ANFIS

FONTE: (FULLÉR, 1995)

Alguns ANFIS possuem restrições em relação aos sistemas de inferência normais e devem atender as seguintes propriedades:

- Deve ser do tipo Sugeno de primeira ou zero ordem;
- Ter uma única saída, obtida com o uso do método da media ponderada, e todas as funções de inclusão de saída devem ser do mesmo tipo e exclusivamente linear ou constante;

- Não compartilhar regras. Regras diferentes não podem compartilhar as funções de inclusão de saída, ou seja, o número de funções de inclusão de saída deve ser igual ao número de regras;
- Deve ter um único peso para cada regra.

2.8 Reconhecimento de Padrões

Apesar do reconhecimento de objetos e suas respectivas classificações em um determinado conjunto ou até mesmo a criação de uma nova classe para incluí-los, seja inerente a capacidade humana; a automatização deste processo é bastante complexa.

O reconhecimento de padrões está relacionado à capacidade de descrição ou classificação de objetos, levando em consideração as suas características. Os objetos são reconhecidos e classificados através de um conjunto de características mensuráveis. A similaridade (MAFRA, 1994) dessas medidas em um determinado grupo de objetos define uma classe.

Dessa forma o objetivo do reconhecimento de padrões consiste em determinar, para uma dada informação, a classe de padrões responsável pela geração de um conjunto de medidas similares dos dados observados, reconhecendo assim, um objeto pela percepção.

Basicamente, um projeto de reconhecimento de padrão se constitui em cinco etapas: aquisição de dados, pré-processamento, extração de características, definição dos parâmetros do classificador e classificação.

Os dados são geralmente adquiridos de sensores, que são instrumentos que fornecem informações físicas mensuráveis de um determinado objeto, ou outra base de dados quaisquer, como um Banco de dados por exemplo. Os sensores mais comumente utilizados são: câmeras, régua, termômetros, satélites, etc.

No pré-processamento são eliminados os ruídos e as distorções geométricas dos objetos. Nesta fase, também, podem ser realizados outros procedimentos capazes de facilitar a interpretação dos dados, como a suavização de curvas, sem interferir em suas características principais.

A extração de características discrimina as propriedades que mais diferenciam um objeto, descartando as características mais comuns desse objeto.

A definição dos parâmetros consiste em definir, da forma mais adequada, os parâmetros do algoritmo escolhido para a classificação.

Na classificação, os objetos são separados em um número finito de classes pré-determinadas.

Geralmente, acrescenta-se um algoritmo de agrupamento antes da classificação com a finalidade de agrupar os objetos por características similares. Em se tratando de imagens, esse processo de agrupamento pode ser realizado através de um algoritmo de sedimentação de imagens.

A Figura 2.21 representa a estrutura básica (DUDA; HART, 1973; SCHALKOFF, 1992) de um classificador.

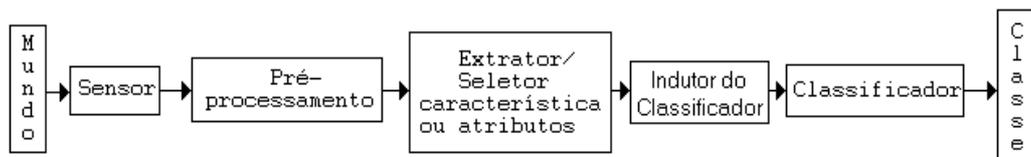


Figura 2.21 Estrutura Básica de um Sistema de Reconhecimento de Padrões

FONTE: (RIBEIRO, 2003)

Os sistemas de reconhecimento de padrões se dividem em dois tipos: supervisionado e não supervisionado.

2.8.1 Métodos não supervisionados

Os métodos não supervisionados se caracterizam por formarem grupos com elementos de características similares entre si e que sejam diferentes dos objetos pertencentes a outros grupos. Esses métodos não possuem algoritmo de treinamento, ou seja, não necessitam de amostras prévias das classes em análise como referência, resultando em agrupamentos de objetos similares.

Um algoritmo de análise de agrupamentos deve apresentar as seguintes propriedades:

- Capacidade de tratar dados de alta dimensionalidade;

- ‘*Escalabilidade*’ no concernente ao número de dimensões e a quantidade de elementos a serem agrupados;
- Capacidade para operar com ruído e discrepâncias;
- Determinação dos parâmetros de entrada com o mínimo de conhecimento dos dados do domínio;
- Operação com vários tipos diferentes de dados;
- Definição de agrupamentos de diferentes tamanhos e formas;
- Insensibilidade à ordem de entrada dos registros de dados;
- Aceitar restrições;
- Encontrar o número ideal de grupos.

A análise de agrupamentos antecede à classificação em alguns sistemas.

Além da classificação e formação de grupos, a análise de agrupamentos evidencia a estrutura camuflada dos dados, possibilitando a redução e o aperfeiçoamento do modelo em abordagem. A análise de agrupamentos está geralmente associada à análise exploratória, envolvendo problemas com pouco conhecimento prévio dos dados.

De uma forma geral os algoritmos de agrupamento podem ser divididos em: por particionamento, hierárquico, baseados em densidade, baseados em grade e baseados em modelo. Desde que os grupos podem ser vistos como subconjuntos de um determinado conjunto de dados, esses métodos podem ainda serem subdivididos de acordo com seus subconjuntos em clássicos ou nebulosos.

Os métodos por particionamento e hierárquico são os mais tradicionais.

Os métodos por particionamento dividem o conjunto de dados em um número determinado de grupos, definido pelo usuário.

Inicialmente, o algoritmo seleciona um número de objetos igual ao definido pelo usuário como sendo os centros dos grupos. Os demais objetos são alocados entre os centros de cada grupo de acordo com medida de similaridade adotada, de forma que cada objeto seja alocado no grupo de menor distância entre o respectivo objeto e o centro do grupo em questão. A partir deste ponto, um processo iterativo de controle determina que objetos devem mudar de grupo, afim de otimizar a função objetivo

utilizada. Os centros dos novos grupos formados são obtidos através da média dos objetos de cada grupo ou pelo cálculo do objeto mais próximo ao centro de gravidade do grupo em questão. Esse processo é repetido até que não haja mudança de elementos entre os grupos.

Um exemplo de função objetivo pode ser dado pela equação:

$$Er = \sum_{i=1}^k \sum \|p - m_i\|;$$

Onde: Er é a soma do erro quadrático para todos os objetos;

p é um determinado objeto;

m é o representante (centróide) do grupo i .

São exemplos de modelo por partição os algoritmos: *k-means* (WONG, 1979), *k-medoids* (ESTER; KRIEGEL; XU, 1995), *fuzzy c-means* (BEZDEK, 1981).

Os algoritmos do modelo hierárquico geram uma decomposição da base de dados, sendo esta decomposição representada por um *dendrograma*, que consiste em uma árvore, representando a divisão da base de dados em subconjuntos menores até que cada subconjunto possua um único elemento. Esta árvore de grupos pode ser construída de forma aglomerativa, na qual inicialmente cada objeto pertence a um grupo e na etapa final todos os objetos pertencem a um único grupo, ou divisiva, em que ocorre o processo inverso. Os métodos AGNES e DIANA (CARLANTONIO, 2001) são exemplos de modelos hierárquicos.

Os métodos baseados em densidade procuram contornar a dificuldade dos métodos baseados no cálculo da distancia em formar grupos de forma arbitrária. Esta abordagem se baseia no fato de que no interior dos grupos a densidade de objetos é consideravelmente maior que fora dos grupos e que a densidade da área de ruídos é menor que a densidade em qualquer grupo. Esse tipo de agrupamento se apóia no conceito de densidade para formar grupos. Podem ser citados como exemplos deste método os algoritmos: DBSCAN e OPTICS (CARLANTONIO, 2001).

Os métodos baseados em grade utilizam uma estrutura em grade de multiresolução, dividindo o conjunto de objetos em um número determinado de

células, formando uma estrutura de grade, na qual todas as operações de agrupamento são realizadas. A rapidez de processamento é a principal vantagem destes métodos, isto se deve a independência do número de objetos, dependendo a velocidade de execução, somente do número de células que formam a grade. São exemplos desta abordagem os métodos: STING, CLIQUE e WaveCluster (CARLANTONIO, 2001).

Nos métodos baseados em modelo, cada grupo é representado por um determinado modelo, tentando aperfeiçoar a curva entre o conjunto de dados em análise e o respectivo modelo. Esses métodos podem formar grupos através de alguma função de densidade que reflita a distribuição espacial dos pontos dos dados em questão. A abordagem através de modelos também possibilita a determinação do número de grupos, baseada na estatística padrão. Os métodos baseados em modelos podem ser abordados de duas formas principais: estatisticamente, como o método COBWEB, e através de Redes Neurais como os mapas auto-organizáveis.

2.8.1.1 Validação

Os algoritmos de agrupamento sempre procuram realizar o melhor agrupamento possível para um determinado número de grupos e parametrizadas formas de grupo. Entretanto não garante o melhor agrupamento, pois o número de grupos pode não ser o mais adequado e a forma dos grupos pode não corresponder aos dados analisados.

A determinação do número de grupos adequado é uma das mais difíceis e importantes tarefas na análise de agrupamentos (CARLANTONIO, 2001), pois raramente o número de grupos é previamente conhecido e, quando é determinado, pode não representar de forma adequada os objetos da análise. Portanto, para contornar este problema, duas principais abordagens podem ser aplicadas:

- Iniciar com um número suficientemente grande de grupos e sucessivamente reduzir este número pela composição de grupos similares de acordo com algum critério previamente estabelecido; e

- Realizar agrupamentos para diferentes números de grupos e avaliar a qualidade de cada partição através de índices de validação. Essa abordagem pode ser de dois modos:
 - Através de um índice de validação que faça a análise de um agrupamento completo, possibilitando a comparação dos diferentes resultados obtidos para cada partição; ou
 - Através da definição de um índice que analise isoladamente cada grupo de uma partição, comparando os resultados obtidos, reunindo os grupos similares e descartando os grupos inadequados, repetindo esse procedimento enquanto existirem grupos discrepantes.

Vários índices de validação estão disponíveis. Entretanto, a eficiência destes índices depende fortemente do tipo de dados abordado, devendo a escolha de um determinado índice ser em função dos dados em análise.

Os índices de validação mais comumente utilizados são:

- i. Coeficiente de Partição (PC)– dimensiona a sobreposição entre grupos, sendo matematicamente definido por:

$$PC(c) = \frac{1}{N} \sum_{i=1}^c \sum_{j=1}^N (\mu_{ij})^2$$

onde: μ_{ij} é o grau de inclusão do elemento j no grupo i ;

O número de grupos mais adequado corresponde ao valor mais alto do coeficiente.

- ii. Classificação por Entropia (CE) – somente quantifica a nebulosidade da partição, sendo similar ao PC, pode ser representado pela seguinte equação:

$$CE(c) = - \frac{1}{N} \sum_{i=1}^c \sum_{j=1}^N \mu_{ij} \log(\mu_{ij});$$

- iii. Índice de Partição (SC) – Avalia a compacidade dos grupos gerados e a separação entre estes grupos, mantendo a exatidão mesmo quando a

sobreposição entre grupos é alta. Pode ser calculado pela seguinte fórmula:

$$SC(c) = \sum_{i=1}^c \frac{\sum_{j=1}^N (\mu_{ij})^m \|x_j - v_i\|^2}{N_i \sum_{k=1}^c \|v_k - v_i\|^2}.$$

O SC é útil para avaliar diferentes partições com mesmo número de grupos. Valores baixos de SC indicam agrupamentos melhores.

- iv. Silhouete (KAUFMAN; ROUSSEEUW, 1990) – Quantifica a similaridade de cada elemento de um grupo em relação aos elementos dos grupos vizinhos. Essa relação é representada em gráficos com forma de silhuetas, podendo ser expresso da seguinte forma:

$$S(i) = \frac{b(i) - a(i)}{\max\{a(i), b(i)\}};$$

podendo ser escrito como:

$$S(i) = \begin{cases} 1 - a(i)/b(i), & \text{se } a(i) < b(i) \\ 0, & \text{se } a(i) = b(i) \\ b(i)/a(i) - 1, & \text{se } a(i) > b(i) \end{cases}$$

onde: $a(i)$ é a media ponderada da dissimilaridade entre um determinado elemento e os demais objetos pertencentes ao mesmo grupo e $b(i)$ é o grupo com a menor media ponderada de dissimilaridade em relação ao respectivo elemento.

O valor do índice para um determinado elemento varia entre -1 e 1. Valores próximos a 1 significam que o elemento está apropriadamente agrupado, valores próximos a -1 indicam que o elemento não esta agrupado de forma adequada, podendo pertencer ao grupo vizinho, e valores próximos de zero indicam que o elemento esta na fronteira entre o respectivo grupo e o grupo vizinho.

A média ponderada de todos os valores de 'Silhouete' para um determinado agrupamento dimensiona a qualidade deste agrupamento, possibilitando a determinação do número de grupos adequado para o conjunto em questão.

Outros métodos para determinação do número apropriado de grupos, como o algoritmo 'subtractive clustering' (CHIU, 1994), também são utilizados. Este algoritmo é uma extensão do algoritmo da montanha (YAGER; FILEV, 1994), assumindo que cada ponto de dado é um potencial centro para um determinado grupo, dimensionando a

probabilidade de cada ponto definir um centro de grupo baseado na vizinhança dos respectivos dados. Basicamente o algoritmo se resume em:

- i. Selecionar os pontos com o maior potencial para ser o primeiro centro de grupo;
- ii. Remover todos os pontos na vizinhança do primeiro centro (determinada pelo raio de influencia), a fim de determinar o próximo grupo e a localização do seu centro;
- iii. Repetir este processo até que todos os dados estejam localizados no raio de influência de um grupo.

2.8.2 Métodos Supervisionados

Os métodos supervisionados se caracterizam pela presença de uma fase de treinamento baseada em amostras representativas das características dos dados em análise em seus processos.

Basicamente, a acurácia de uma classificação depende da representatividade das estimativas da quantidade e das características estatísticas das classes presentes no conjunto da análise, e das restrições sobre o conjunto de dados, no qual se baseia o método de classificação. O modo de abordagem das restrições varia de acordo com a técnica utilizada. A qualidade das estimativas depende do tamanho e representatividade das amostras. Desta forma, a estimativa da quantidade de amostras e a seleção das amostras de referência são fundamentais para um desempenho apropriado de um classificador supervisionado.

O ajuste dos parâmetros de um classificador através de amostras de treinamento pode não resultar no desempenho esperado para um conjunto de teste. A capacidade de generalização de um classificador está relacionada ao seu desempenho em classificar padrões que não participaram do conjunto de amostras de treinamento.

Uma capacidade de generalização insuficiente pode ser resultante dos seguintes fatores:

- Número de características muito grande em relação ao número de amostras de treinamento;
- Grande número de parâmetros desconhecidos;
- Sobre-treinamento.

O sobre-treinamento pode ser absoluto, quando o desempenho se degrada para todas as categorias de padrões, e relativo, quando o desempenho se degrada para determinadas categorias, não sendo influenciado por outras.

A dominância de padrões de algumas categorias ou a apresentação de padrões confusos nas regiões de fronteira podem resultar em sobre-treinamento relativo.

O conceito de sobre-treinamento se refere à exagerada adaptação e ajustes dos parâmetros do classificador a padrões específicos, acarretando a perda da generalização.

O tamanho das amostras, o número de características dos padrões e sua complexidade influenciam diretamente o desempenho de um classificador.

Os métodos supervisionados mais utilizados são: Paralelepípedo, Mínima Distância, K-Vizinhos Próximos (KNN), Máxima Verossimilhança, Redes Neurais, Baseados em Regras Nebulosas, Sistema Neuro-Nebuloso e Algoritmos Genéticos.

2.8.2.1 Avaliação

A avaliação de uma classificação consiste basicamente na comparação de uma classificação de referência, que expresse corretamente as categorias de interesse, com a classificação obtida através do procedimento em análise. A matriz de confusão e o coeficiente kappa são dois modos de proceder esta avaliação. Outras medidas como: acurácia do produtor que calcula o percentual de elementos classificados corretamente pelo algoritmo em relação à classificação de referência, acurácia do usuário que verifica o percentual de elementos da classificação resultante que foram classificados adequadamente segundo a classificação de referência, e acurácia global que expressa a razão entre a soma de todos os elementos corretamente classificados (traço da matriz de confusão) e o número de elementos analisados; também podem ser utilizadas.

A matriz de confusão é uma matriz quadrada em que as colunas representam os valores da classificação de referência e as linhas os resultados obtidos com o método da análise. A matriz de confusão permite a visualização dos resultados, expressando a relação entre os erros de inclusão quando um elemento que não pertence a uma determinada classe na classificação de referência é a ela atribuído e de omissão quando um elemento que pertence a uma determinada classe na classificação de referência não é a ela atribuído. Os elementos da matriz diagonal representam os objetos corretamente classificados, os elementos acima da diagonal representam os erros de omissão e os elementos abaixo os erros de inclusão. Uma classificação perfeita é representada por uma matriz de confusão somente com os valores dos elementos da diagonal principal diferentes de zero.

O coeficiente Kappa é uma medida estatística que procura avaliar a eficiência de uma classificação baseada em uma classificação de referência. Diferentemente da acurácia global que somente leva em consideração o traço da matriz de confusão, o coeficiente kappa considera todos os elementos da matriz de confusão, podendo ser representado pela seguinte equação:

$$kappa = \frac{\sum_{i=1}^n x_{ii} - \frac{\sum_{i=1}^n (x_{i+} \cdot x_{+i})}{N}}{1 - \frac{\sum_{i=1}^n (x_{i+} \cdot x_{+i})}{N^2}}$$

- onde:
- n : o número de classes
 - x_{ii} : o i -ésimo elemento na diagonal da matriz de confusão
 - x_{i+} : total de pontos classificados como sendo da classe i
 - x_{+i} : total de pontos pertencentes à classe i
 - N : o número total de pontos avaliados

O coeficiente kappa pode ser negativo em casos extremos.

A

Tabela 2.5 mostra uma interpretação textual, mais compreensível para os valores mais comuns de kappa.

Tabela 2.5 interpretação dos valores do coeficiente kappa

Kappa	Significado
0.0 — 0.20	Péssima
0.21 — 0.40	Fraca
0.41 — 0.60	Razoável
0.61 — 0.80	Boa
0.81 — 1.00	Excelente

3 Trabalhos Relacionados

Jonathan, em sua dissertação de Mestrado (JONATHAN, 2005), sugere uma metodologia para classificação do uso e cobertura do solo, utilizando dados do sensor MODIS. O método abordado faz uso de algoritmos estatísticos convencionais para tratamento e classificação das imagens obtidas, alcançando resultados aceitáveis de classificação. Um dos pontos interessantes em seu trabalho é o uso dos dados de qualidade fornecidos pela NASA para filtrar os pixels que não satisfizessem os critérios previamente estabelecidos, esses pixels seriam substituídos por técnicas de interpolação, aumentando, desta forma, a confiabilidade dos dados. As séries temporais são tratadas de forma direta sem aplicação de nenhum método para reduzir a sua dimensionalidade. O autor usa formatos de arquivos não muito comuns, bibliotecas proprietárias e um aplicativo para extração de características dos dados em questão, sugerindo o uso da Lógica Nebulosa para abordagem dos *pixels* misturados, principalmente levando em consideração a resolução do sensor (250m).

Já Anderson, em sua tese (ANDERSON, 2004), propõe uma classificação não supervisionada de dados MODIS utilizando-se de técnicas convencionais, através de um aplicativo que trabalha internamente com seu próprio formato de dados. A autora procura resolver o problema dos *pixels* misturados através das proporções da mistura espectral, agregando ao NDVI as imagens proporções de solo, sombra e vegetação resultantes da análise da mistura espectral. Os dados foram tratados sem mecanismos que reduzissem as suas dimensionalidades.

Noguchi, em sua dissertação (NOGUCHI, 2004), relata um sistema baseado em regras nebulosas para classificação supervisionadas de imagens multiespectrais. Apesar desta solução não se aplicar a dados de média resolução, mostra claramente o potencial da Lógica Nebulosa na classificação de dados de satélites.

Gleriani, em seu artigo (GLERIANI; EPIPHANIO; SILVA, 2005), propõem o uso de Redes Neurais Artificiais para classificação de culturas agrícolas. Embora o método proposto não seja adequado para dados do sensor MODIS, evidencia de forma clara as vantagens do uso de Redes Neurais neste tipo de abordagem.

Sengur, em seu artigo (SENGUR, 2008), aborda o uso da Transformada *Wavelet* e do sistema ANFIS para análise de textura em imagens coloridas. Apesar desta abordagem não se aplicar especificamente a séries temporais evidencia o sucesso destas tecnologias na redução da dimensionalidade dos dados e geração de regras automáticas segundo o autor.

Derya, em seu trabalho (DERYA; ÍBEYLI, 2008), descreve a aplicação dos coeficientes da Transformada *Wavelet* como dados para implementação de um sistema de inferência nebulosa baseado no sistema ANFIS para detecção de desordens em artérias oftálmicas. A complexidade desses dados atestam a boa performance da Transformada *Wavelet* aliada ao sistema ANFIS na solução deste tipo de problema.

O trabalho de Picoli (PICOLI, 2007) consiste em estimar a produtividade da cana de açúcar em uma determinada usina através da utilização de variáveis qualitativas e quantitativas em um modelo de agregados de Redes Neurais. Uma das variáveis utilizadas foi o índice de área foliar (IAF) obtido para cada talhão de cana a partir do NDVI extraído de imagens do sensor MODIS durante o período de crescimento da cultura da cana. Segundo a autora, os modelos propostos apresentaram resultados satisfatórios.

Ribeiro e Centeno, em seu artigo (RIBEIRO; CENTENO, 2001), comparam o algoritmo estatístico de Máxima Verossimilhança com Redes Neurais, baseadas no algoritmo retropropagação, para classificar imagens das bandas 5, 4 e 3 do satélite LandSat-TM. Esse trabalho constatou que o desempenho das RNAs foi sensivelmente

melhor que o do algoritmo estatístico devido à pequena quantidade de amostras de treinamento segundo os autores.

Mas (MAS, 1996) utiliza regras de inferência nebulosa para analisar a mistura espectral de classes de espécies vegetais em seu trabalho. O autor concluiu que os graus de inclusão de um determinado elemento para cada classe objeto da análise possibilitam a análise da mistura espectral.

4 Metodologia

Embora a metodologia proposta possa processar vários tipos de séries temporais, este trabalho concentrou a sua aplicação nos dados provenientes do sensor MODIS.

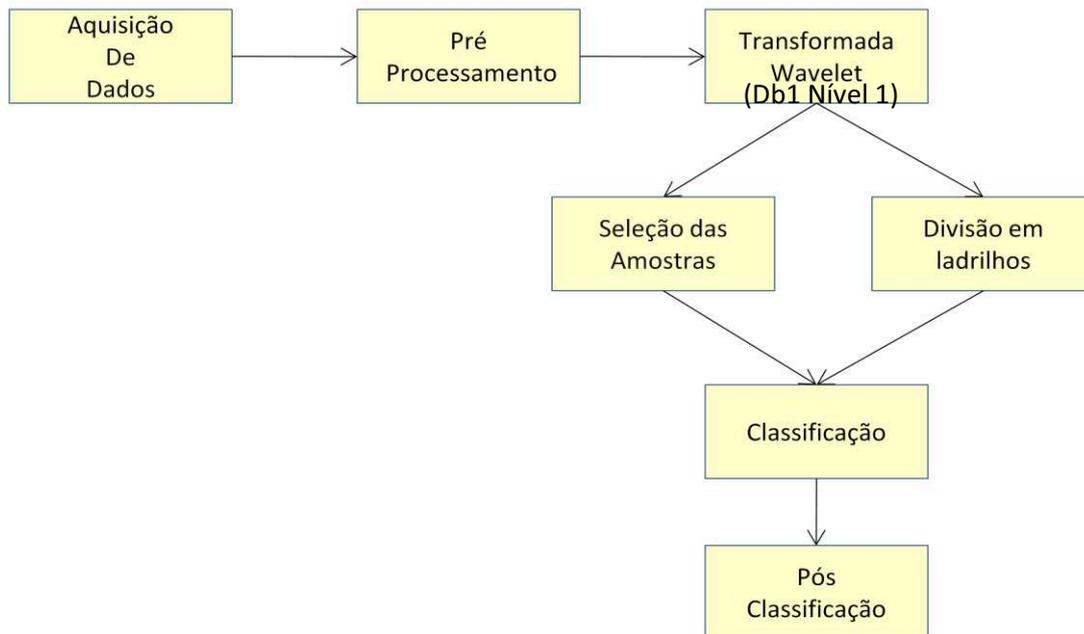


Figura 4.1 Visão Geral da Metodologia

A primeira etapa consistiu em uma análise dos principais tipos de dados e produtos disponibilizados por esse sensor, já que foi o escolhido para realização deste trabalho. O sensor MODIS possui dentre as suas principais vantagens: a gratuidade de suas imagens, produtos acabados com as correções básicas realizadas pela NASA e a sua alta resolução temporal. Como característica negativa pode-se citar uma baixa resolução espacial.

Entre os produtos oferecidos pela NASA (NASA, 2007), optou-se pelo MOD13Q1 (seção 2.2.1) por possuir como características relevantes o fato de fornecer o NDVI baseado na refletância real e associar a seus dados, informações relativas à qualidade de cada ponto adquirido.

O NDVI (seção 2.1.2) se utiliza da banda do vermelho e infravermelho, que possuem a melhor resolução espacial do sensor (250m), e, por ser uma razão entre duas bandas do satélite, possibilita a correção de algumas discrepâncias que eventualmente possam ocorrer. Além disso promove uma redução da

dimensionalidade dos dados. Esse Índice tem uma utilização bastante aceita e apresenta bons resultados ao descrever os diferentes estágios da vegetação (JUSTICE, 1985) ou a fenologia agrícola (BENEDETTI; ROSSINI, 1993; XIN; VAN LEEUWEN; DRIESSEN, 2002).

As informações de qualidade possibilitam a filtragem dos dados de consistência duvidosa através do algoritmo de interpolação bicúbica (JONATHAN, 2005).

Segue-se à esta etapa, a aquisição dos dados definidos na fase anterior.

Os dados do sensor foram obtidos diretamente do site da NASA (NASA, 2007), em seu formato original, transformados do formato 'hdf', difícil de ser interpretado para o formato 'GeoTIFF', facilmente acessível, e, posteriormente, convertidos da projeção sinusoidal para a projeção UTM, a mesma da verdade terrestre. Os dados da verdade terrestre necessária a avaliação do procedimento foram fornecidos pela EMBRAPA (EMBRAPA, 2008), na projeção UTM e no formato 'TIF'.

A fase seguinte é o pré-processamento (seção 2.3) dos dados obtidos, que é responsável pelo tratamento inicial dos dados, a fim de auxiliar o processo de análise.



Figura 4.2 Fase de Pré-processamento

O primeiro passo foi a transformação dos dados do sensor para a projeção UTM (*Universal Transverse Mercator*) e para o formato 'TIF'. Este é o único procedimento que se utiliza de um aplicativo para sua execução, devendo-se este fato a própria sugestão da NASA de se utilizar o aplicativo MRT (*Modis Reprojection Tool*) para a realização desta tarefa, isto foi necessário devido aos dados originais deste produto fazerem uso da projeção sinusoidal e do formato HDF, poucos usuais. Desta Forma, visando tornar mais fácil a manipulação destes dados, essas características bastantes particulares dos produtos MODIS foram transformadas respectivamente em representações mais comuns e fáceis de serem processadas.

Após este processo, as imagens são transformadas em séries temporais e processadas no domínio do tempo, a fim de se obter perfis temporais mais suaves.

Para isso, realiza-se a filtragem desses dados, baseada nas informações de qualidade fornecidas pelo produto MOD13Q1 (NASA, 2007), estabelecendo-se critérios de qualidade e, substituindo os dados que não alcancem estas condições através de algoritmos de interpolação (bicúbica). Baseado no trabalho de Jonathan (JONATHAN, 2005), os seguintes critérios foram adotados: NDVI produzido provavelmente sem nuvens (bit1 igual a '0'), utilidade de NDVI media ou superior (bit5 igual a '0'), quantidade de aerossóis (bit6 e 7 diferentes de '11'), ausência de nuvens misturadas (bit 10 igual '0'), ausência de sombra (bit 14 igual '0').

Ainda com o intuito de amenizar os pixels discrepantes que não puderam ser eliminados na etapa anterior devido a falhas nas informações contidas nos metadados, segue-se, então, a passagem das imagens por um filtro que realize tal tarefa. Com esse propósito, dois filtros foram analisados: um filtro de média de janela três e um outro filtro também de janela três, em que os pixels que ultrapassarem os valores da média mais o desvio padrão ou da média menos o desvio padrão serão substituídos pelos respectivos valores das operações da média com o desvio padrão. O filtro que considera o desvio padrão obteve uma melhor resposta eliminando os pixels isolados com uma menor interferência na vizinhança do pixel em questão. Apesar da boa qualidade dos dados após estes procedimentos, os perfis temporais das diferentes classes de interesse ainda podem se mostrarem bastante irregulares. Com o intuito de diminuir essas irregularidades, são obtidos perfis mais suaves através do ajuste de curvas polinomiais. Após a realização desses procedimentos os dados estão preparados para as próximas etapas da metodologia.

Na próxima fase é aplicada uma Transformada *Wavelet* (BULTHEEL 2003) sobre os dados a serem processados, extraindo os coeficientes que serão utilizados nas fases de agrupamento (CRUZ) e classificação, objetivando a redução das dimensões do conjunto de dados a ser analisado. O uso dessa técnica, dependendo do nível da função utilizada, possibilita uma perda mínima da informação temporal contida nos dados, diferentemente de outras abordagens, como: Análise dos Componentes Principais (PCA) e Transformada de Fourier, que não conservam a preciosa informação de tempo contida nos dados originais. Outro ponto interessante é que as funções

wavelet, por funcionarem como filtros, promovem uma suavidade da curva em pontos discrepantes.

Como exemplos de aplicações da Transformada *Wavelet* em Sensoriamento Remoto, pode-se citar: a remoção do ruído speckle em imagens de radar (HORGAN, 1998), a composição de imagens de alta resolução espectral com imagens de alta resolução espacial (LUCCA, 2006; YOCKY, 1996; ZHOU, 1998), e na análise e classificação de texturas (ZHU; YANG, 1998). O trabalho de Epinatl (EPINATL; STEIN; JONG *et al.*, 2001) relata a classificação de padrões NDVI de alta resolução em agricultura de precisão.

Nessa etapa foi realizada uma análise com diversas funções *wavelet* com o objetivo de se determinar qual a mais adequada para o problema em questão, já que não existe uma receita única com esta finalidade. Fernanda e Fernando (FERNANDA I. M. ARGOUD; FERNANDO M. DE AZEVEDO; NETO, 2004) sugerem uma metodologia para seleção da Transformada *Wavelet* mais adequada em uma determinada área de atuação, entretanto essa metodologia está restrita ao âmbito de atuação da área relacionada ao seu trabalho, já que sinais diferentes podem ser representados por *wavelets* distintas. Segundo Domingues (DOMINGUES; JÚNIOR; COSTA, 2003), a forma da função *wavelet* escolhida deve refletir as características da série temporal, observando que séries temporais com variações bruscas ou degraus podem obter melhor resposta com a *wavelet* de Haar; enquanto que para as séries temporais com variações mais suaves, as *wavelet* de Morlet e chapéu mexicano podem ser as mais indicadas. Ainda segundo (DOMINGUES; JÚNIOR; COSTA, 2003), as funções *wavelet* ortogonais representam os sinais de forma mais compacta. Desta forma, foram analisadas as funções ortogonais de Haar e Daubechies de ordens 1, 2, 3 e 4. Os melhores resultados foram obtidos com a função de Daubechies de ordem 1 no nível um (db1), pois no nível dois, embora a desejável redução de dimensionalidade fosse maior, percebeu-se uma perda de informação suficiente para influenciar o agrupamento do conjunto de dados. Os coeficientes de aproximação resultantes da Transformada *Wavelet* são os dados utilizados nos procedimentos subseqüentes. A Figura 4.3 mostra o exemplo de um agrupamento com os coeficientes *wavelet*, de um conjunto de séries temporais, originados de uma transformação, aplicando-se a função

de Daubechies1 no nível 1 e os agrupamentos dos dados originais. Visualmente podemos notar a formação de grupos homogêneos que representam claramente as classes pertencentes a este conjunto de dados.

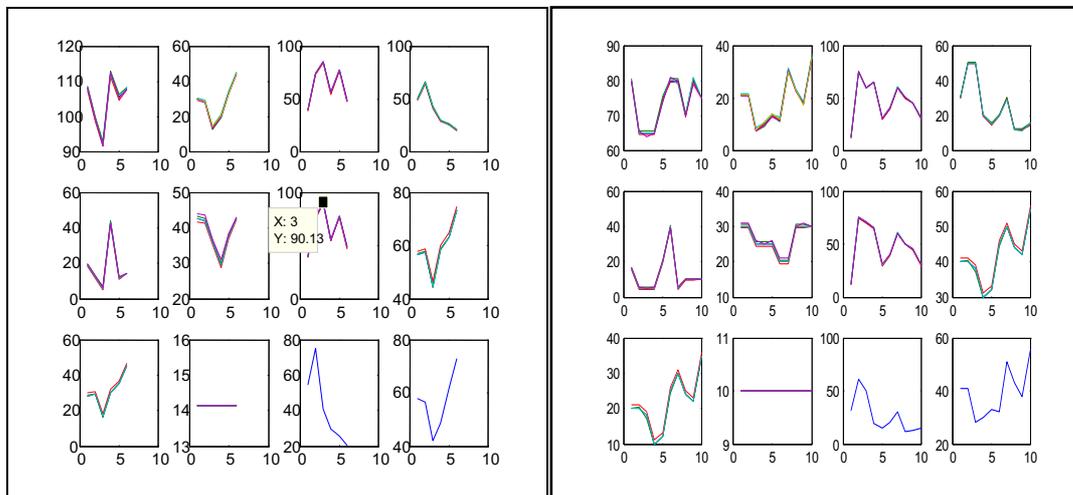


Figura 4.3 Agrupamento com Coef. Wavelet a esquerda e com Dados Originais a direita

Uma das etapas mais importantes em classificações supervisionadas refere-se à seleção dos dados de treinamento (seção 2.5.2), principalmente em problemas com dados de alta complexidade. Em muitos trabalhos nesta área, não se observa o devido cuidado nesta fase, com as amostras sendo escolhidas aleatoriamente nas imagens, sem nenhum critério científico. Este tipo de abordagem pode se mostrar ineficiente, pois devido a variáveis, como: época de plantio, tipo de solo, luminosidade e umidade abordadas no artigo de Canavesi (CANAVESI; COURA; FORMAGGIO *et al.*, 2005), uma única classe de vegetação pode ser representada por várias séries temporais distintas, levando a uma classificação insuficiente, se estas peculiaridades não estiverem devidamente representadas nos dados de treinamento. De outra forma, o excesso de amostras pode redundar em treinamentos desnecessariamente complexos. O que pode levar a classificações equivocadas e a situação de sobre-treinamento, levando a não generalização em casos onde a quantidade de amostras para uma determinada classe é muito maior que para as demais.

Objetivando corrigir este problema, nesta fase os dados das séries temporais serão agrupados de acordo com os dados de referência (Verdade Terrestre) selecionados. Em seguida, cada grupo será reagrupado através de algoritmos de

agrupamentos (não supervisionados), a fim de se obter a quantidade e as classes discrimináveis em cada grupo. Dessa forma determina-se os diferentes representantes de cada classe objeto da análise. O número de grupos em cada conjunto será determinado através dos algoritmos '*Subtractive Clustering*' (CHIU, 1994) e '*Silhouette*' (KAUFMAN; ROUSSEEUW, 1990). O algoritmo '*Subtractive Clustering*' foi escolhido por ser capaz de estimar o número de grupos em um determinado conjunto de dados através do raio de influência de cada dimensão dos dados em questão, permitindo assim se determinar o número de grupos discrimináveis, de acordo com as necessidades de cada data. Outro motivo de sua escolha envolve sua capacidade de retornar os centróides de cada grupo, que serão utilizados na classificação supervisionada. O algoritmo '*Silhouette*', devido as suas características de avaliar agrupamentos e, também, por ser aplicável em dados multidimensionais, será utilizado para analisar os agrupamentos obtidos.

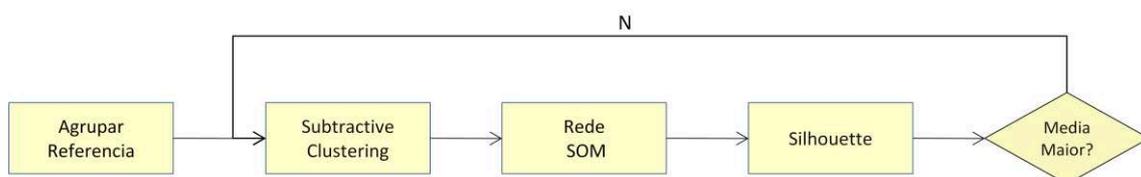


Figura 4.4 Seleção das Amostras

Este processo de agrupamento se realizará da seguinte forma: inicialmente, se aplicará o algoritmo '*Subtractive Clustering*' em um dos grupos de referência originado da verdade terrestre, obtendo-se o número de clusters de acordo com o raio de influência desejado para cada dimensão. Em seguida, uma rede auto organizável de Kohonen (KOHONEN, 2001), projetada com o número de neurônios determinado pelo algoritmo '*Subtractive Clustering*', será aplicada, a fim de formar grupos com o conjunto de dados em análise. A seguir, estes grupos serão avaliados com o algoritmo '*Silhouette*' de modo a se conseguir um agrupamento eficiente. Este processo deve ser repetido até se obter um agrupamento adequado. Uma maneira de se automatizar esse processo é comparar a média do resultado do algoritmo '*Silhouette*' até se

alcançar a maior, sendo esse agrupamento considerado o desejado. Esse procedimento deve ser realizado para as todas as classes de interesse.

Optou-se pelo uso do raio de influência para determinação do agrupamento desejado, por este se apresentar mais intuitivo do que se arbitrar o número de grupos iniciais, pois esta quantificação é difícil de presumir em séries complexas. Além disto, o raio de influência nos permite definir o rigor do agrupamento em cada ponto da série, de forma que para raios menores obteremos um número maior de grupos com um número de elementos menores. Desta forma, se permite uma seleção mais severa ou mais resumida dos representantes de cada classe, simplesmente variando o raio de influência. Além disto, o raio de influência nos possibilita determinar a importância de cada data da série no agrupamento, bastando, para isso, atribuir-se raios menores a datas de maior interesse, fazendo com que o agrupamento seja mais rigoroso para estas datas. Outra vantagem é que o grau de influência inicial pode ser arbitrado automaticamente, por exemplo, através do cálculo da variância de todo o conjunto de dados, atribuindo-se, então, graus proporcionais as variâncias de cada data.

De modo a se poder estabelecer comparações, os algoritmos K-Means e Fuzzy C-Means (MANN, 2003) também serão avaliados para o processo de agrupamento propriamente dito. Os pesos dos mapas de Kohonen (seção 2.5.3) obtidos nesta fase servirão como pesos iniciais para o processo de classificação.

O fato dos dados serem divididos de acordo com as classes de interesse proporciona uma maneira de se obter os melhores representantes para cada classe, além de propiciar agilidade e flexibilidade a metodologia, visto que podemos analisar cada grupo de classes de interesse de uma vez, em caso de recursos limitados (pouca memória); ou todos os grupos em paralelo no caso de uma rede de computadores.

Em uma nova fase, as séries de coeficientes *wavelets* serão divididas em grupos relativos aos ladrilhos nas imagens originais. Da mesma forma que no agrupamento das classes de interesse, este procedimento visa tornar as fases subseqüentes mais ágeis e flexíveis, visto a grande massa de dados em larga escala que necessita ser processada. Deste modo, cada ladrilho poderá ser processado isoladamente em caso de sistemas com pouca memória ou plataformas que somente funcionam bem até um limiar de memória (Java); ou os ladrilhos poderão ser processados paralelamente nos

casos de sistemas distribuídos (rede), permitindo o máximo de aproveitamento dos recursos, quer sejam eles escassos ou abundantes, levando-se em conta que estes ladrilhos podem ser de tamanho variado de acordo com as necessidades de cada caso.

Na etapa de classificação, serão realizadas duas abordagens : ANFIS e mapa de Kohonen. O mapa de Kohonen além da classificação, também será utilizado no levantamento dos perfis temporais das classes que não possuem amostras representativas de suas características, mas que também pertencem à área de análise, sendo de grande importância para o sistema ANFIS (DERYA; ÍBEYLI, 2008; SENGUR, 2008).

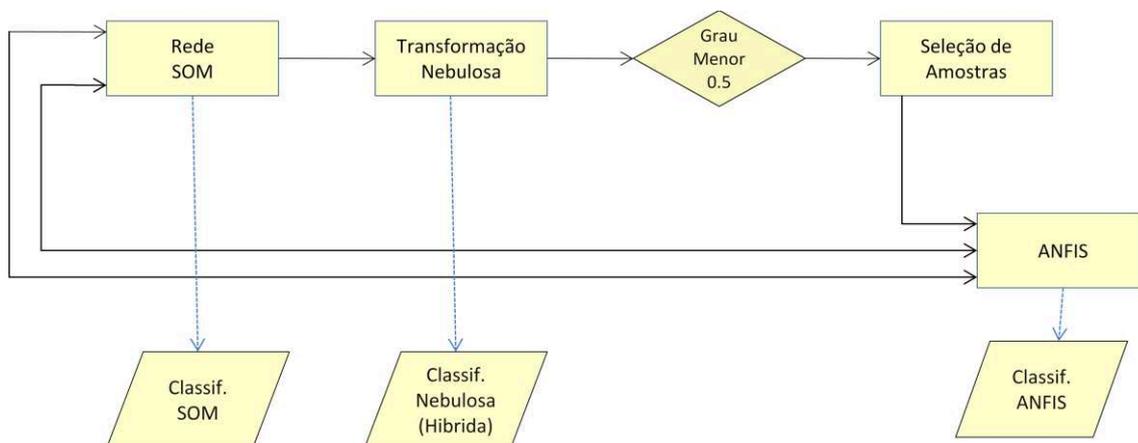


Figura 4.5 Visão da Fase de Classificação

O sistema ANFIS foi utilizado por automatizar a obtenção das regras de um modelo de inferência nebulosa, tarefa que pode ser muito complicada em sistemas complexos como séries temporais, e também por possibilitar a inclusão de novas regras. Sugerindo assim uma forma não muito abordada, mas que poderá ser eficiente no concernente ao tratamento deste problema, ou seja, a criação de um modelo nebuloso baseado em regras para classificação das séries temporais do sensor MODIS.

As duas abordagens foram utilizadas para efeito de comparação, principalmente do sistema ANFIS e suas perspectivas.

Nesta fase um novo mapa de Kohonen será gerado tendo como pesos todos os pesos derivados da fase anterior, e como número de neurônios o somatório dos números de clusters obtidos de cada classe na fase anterior.

Em seguida aplicam-se, à rede projetada, as séries temporais de cada ladrilho, obtendo-se assim suas classificações, já que cada neurônio da rede está relacionado a uma classe de interesse.

A classificação resultante será transformada em nebulosa através da aplicação da fórmula do algoritmo *Fuzzy Cmeans* (MANN, 2003), relacionando as séries temporais com os pesos da rede, resultando, desta forma, em um sistema híbrido.

Esse processo objetiva dotar a classificação de um mecanismo que trate de forma adequada a mistura de classes e de maior flexibilidade, já que propiciará um controle sobre o rigor do resultado. Para isto, basta variar o grau de inclusão das classes de interesse, podendo-se obter, por exemplo, uma classificação rigorosa em que somente serão consideradas as séries com grau de inclusão maior 0.8 (alto grau de certeza), ou uma com menor exigência em que serão consideradas as séries com grau maior que 0.5. Outra vantagem dessa abordagem nebulosa está relacionada ao fato de se poder analisar o potencial de um elemento pertencer a uma determinada classe, o que não é possível em uma classificação tradicional, já que neste tipo de classificação um elemento pertence ou não a uma classe, fato que pode levar em alguns casos a resultados indesejáveis.

Além dos motivos citados, a Lógica Nebulosa (seção 2.6), neste trabalho, também foi utilizada para se determinar as séries que não pertence a nenhuma classe de interesse, considerando para isto as classes com grau de inclusão menor que 0.5.

Na abordagem relativa ao sistema ANFIS, as séries não classificadas pelo mapa de Kohonen passarão pelo mesmo processo de seleção das amostras já descrito anteriormente, resultando em mais um conjunto de amostras que se somará aos já determinados para a rede de Kohonen. A determinação de amostras para as séries não conhecidas é importante para o treinamento do sistema ANFIS, devido sua alta sensibilidade à base de treinamento. Neste caso, amostras insuficientes levariam todas as séries a serem classificadas pela referência mais similar, induzindo a resultados

imprecisos para as séries de perfis muito diferentes das classes de interesse, dificultando uma análise direta mais precisa deste sistema.

O sistema ANFIS adotado terá como base para geração automática das regras iniciais o algoritmo *Subtractive Clustering*, tendo como raios de influencia a média dos raios obtidos na fase de seleção das amostras. Esse sistema, após devidamente treinado, classificará os mesmos dados submetidos à rede de Kohonen.

Finalmente, os resultados das classificações serão reagrupados em mapas e passarão por um processo de pós-classificação. Nesse processo, um filtro detectará, os pixels cuja vizinhança direta exceda seis *pixels*, pertencentes a uma mesma classe e que sejam diferentes do pixel em questão, atribuindo a este pixel a classe da maioria, contribuindo assim para a obtenção de um perfil mais suave dos mapas de classificação. A Figura 4.6 mostra um fluxograma completo da metodologia.

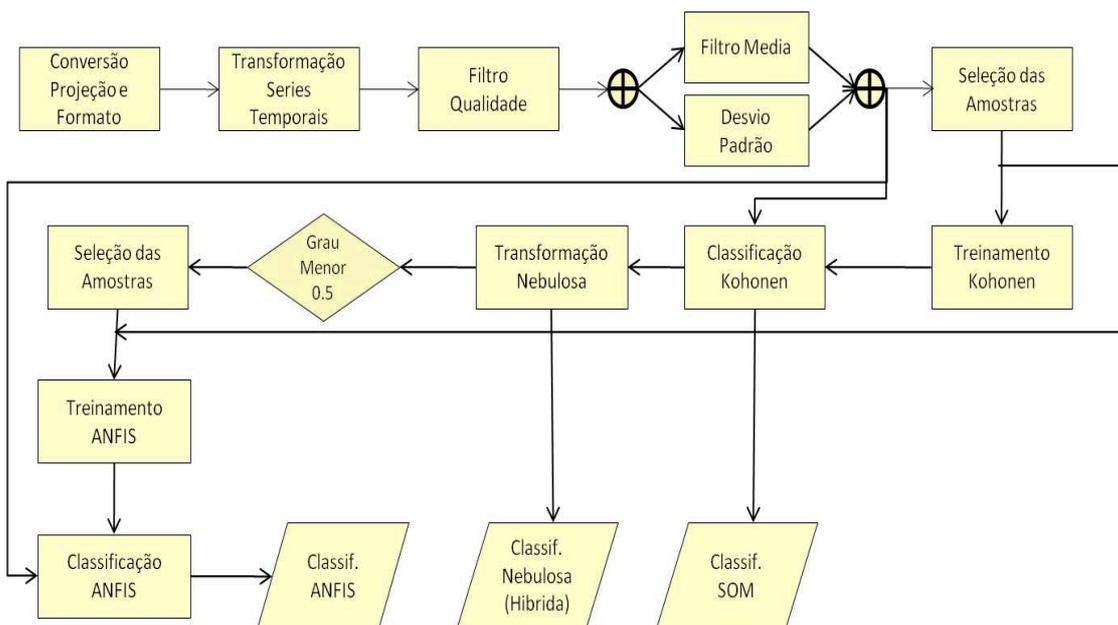


Figura 4.6 Fluxograma da metodologia

Neste capítulo, foram apresentados, os procedimentos da metodologia proposta. Valendo-se ressaltar que todas as etapas são totalmente automatizáveis, pois, com exceção da conversão da projeção, sugerida pela própria NASA, todas as fases independem de aplicativos prontos e da interferência humana no processo, diferentemente da maioria das metodologias que ficam atreladas a estes tipos de necessidades. Pode-se frisar ainda que mesmo o processo de projeção e a conversão do formato do arquivo podem ser facilmente automatizados pelo uso de bibliotecas

gratuitas que trabalham com a projeção sinusoidal e o formato 'hdf'. A automatização pode ser alcançada pelo desenvolvimento dos algoritmos propostos e com o uso de pacotes de funções (*software* aberto) que implementem as tecnologias abordadas.

Pode-se notar que a metodologia em questão é flexível, não somente no que se concerne ao aspecto computacional, mas também quanto a sua aplicação, já que pode facilmente ser aplicada em qualquer região, bastando, para isto, uma pequena amostra de dados do local em questão e um novo treinamento. A única limitação está relacionada ao tamanho de classes menores que duzentos e cinqüenta metros, mas isto se deve a resolução do sensor e não a metodologia em si. A quantidade de amostras está relacionada à qualidade da classificação, pois quanto maior a quantidade de informação relativa aos vários perfis temporais de cada espécie, melhor será a escolha de seus representantes. O que não impede de se obter uma boa classificação com uma amostra reduzida de dados, alcançando-se assim uma classificação de baixo custo financeiro e computacional de uma grande massa de dados.

O resultado dessa abordagem são classificações nebulosas e não nebulosas, permitindo, desta maneira, uma flexibilidade quanto ao rigor e a interpretação dos mapas temáticos gerados, para isto, basta simplesmente variar ou analisar os graus de inclusão das classes de interesse.

A principal contribuição dessa metodologia é o baixo custo financeiro e computacional a ela agregados, visto a complexidade e quantidade da massa de dados de interesse (larga escala), bem como a análise e aplicação de técnicas consagradas em outras áreas. Todavia, outras vantagens também são relevantes, como: alto grau de automação, flexibilidade, facilidade de integração, independência de ferramentas prontas e independência de um especialista em interpretação de imagens.

Quanto à necessidade de equipamentos, poderia se utilizar desde uma máquina com 256 MB de RAM até uma rede de computadores de alta performance, pois a metodologia, devido a sua flexibilidade no tratamento dos dados, se adaptaria a aos recursos disponíveis.

Quanto aos algoritmos utilizados, encontram-se disponíveis bibliotecas em diversas linguagens como: C++, *Python* e Java que fornecem funções que executam os procedimentos necessários. A única exceção é o sistema ANFIS, o qual não se encontram facilmente pacotes de funções que o implementem adequadamente.

O reaproveitamento de código permite a fácil realização de uma seqüência de procedimentos que executem a metodologia proposta. Os dados de entrada deste processo devem ser: as imagens temporais da área de interesse, os valores de referência (Verdade Terrestre) em caso de treinamento, os raios de influência inicial de cada data (valores de zero a um) e o tamanho de cada ladrilho, tendo como resultado as classificações desejadas. Conseguindo-se assim a automatização de toda a metodologia, inclusive da fase treinamento caso haja necessidade.

5 Estudo de Caso

Devido à dificuldade de se encontrar uma verdade terrestre que realmente expresse a classificação de uma determinada região, visto que vários parâmetros além do foco da classificação interferem no resultado, optou-se pela realização de dois experimentos: um com dados simulados (controlado) e um caso real, a fim de se realizar uma melhor análise. A avaliação se fará através de gráficos, da matriz de confusão (seção 2.8.2.1) e do cálculo do coeficiente Kappa (JONATHAN, 2005), os quais são procedimentos padrão para avaliações de trabalhos nesta área.

A seqüência de procedimentos necessários a execução da metodologia foi elaborada no “Matlab” (MATHWORKS, 2006) com a utilização das ferramentas de processamento de imagem, estatística, Redes Neurais, *Wavelet* e Lógica Nebulosa. Os parâmetros de entrada são as imagens simuladas ou reais, as referências, o tamanho de cada ladrilho e raio de influência, desta forma, automatizando também a fase de treinamento. No final deste processamento obtemos mapas (classificações) rígidos e nebulosos através do uso de mapa de Kohonen ou do sistema ANFIS, alcançando-se assim um procedimento totalmente automatizado para análise em questão.

5.1 Dados Simulados

Este experimento tem o intuito de analisar os processos de agrupamento, Rede de Kohonen, a Lógica Nebulosa e o sistema ANFIS, sem a interferência de fatores externos inconsistentes como: verdade terrestre e sinais com ruídos desconhecidos provenientes do próprio sensor ou de variáveis atmosféricas (numero de aerossóis, chuva, luminosidade). Visto que, neste ensaio, as séries temporais são controladas, ou seja, sem ruídos indesejáveis e a verdade terrestre espelha exatamente as classes envolvidas.

5.1.1 Materiais

As imagens necessárias a este experimento foram geradas através do desenvolvimento de um código específico para esta tarefa no aplicativo 'Matlab' (MATHWORKS, 2006). Esse processo permite a geração de imagens de qualquer tamanho, a partir de sinais de referência, que no caso, são amostras puras de assinaturas espectro temporais conhecidas. Também é possível, a inserção de distorções em forma de percentuais, aleatórias ou determinadas de acordo com o interesse da análise nos sinais originais. Estes ruídos são úteis no sentido de se analisar a mistura de classes e a Lógica Nebulosa. As datas de ocorrência dos ruídos também podem ser determinadas de forma aleatória ou específica. A verdade terrestre é gerada automaticamente de acordo com as classes de interesses estabelecidas.

Assim sendo, foram geradas doze imagens de largura e altura iguais a duzentos e cinquenta e seis *pixels*, com ruídos aleatórios de dez a trinta por cento em datas não determinadas. As séries com ruído menor que dez por cento foram consideradas com sendo da classe original e as de maior discrepância como não classificadas, na geração da verdade terrestre. A geração de classes diferentes, porém muito similares foi proposital com o intuito de avaliar o desempenho da metodologia nestes casos.

5.1.2 Aplicação da metodologia e avaliação.

Aplicaram-se os procedimentos automatizados descritos anteriormente aos dados gerados, obtendo-se então os mapas de classificação relativos aos dados em questão. Em seguida, as matrizes de confusão necessárias à análise foram obtidas. Vale ressaltar a atribuição de nomes de culturas agrícolas às classes de interesse, meramente para facilitar as observações sobre a análise, sem nenhuma pretensão de comprometimento com perfis reais.

Tabela 5.1 Matriz de confusão de uma classificação híbrida usando Kohonen

	não class	Feijão1	Feijão2	Sorgo	Milho	Cana1	Cana2	Feijão1R	Feijao2R	SorgoR	MilhoR	Cana1R	Cana2R	Total	acur. rel. %
não class	10240	0	0	0	0	0	0	0	0	0	0	0	0	10240	100.00
Feijão1	0	128	0	0	0	0	0	128	0	0	0	0	0	256	50.00
Feijão2	0	0	640	0	0	0	0	0	640	0	0	0	0	1280	50.00
Sorgo	0	0	0	512	0	0	0	0	0	0	0	0	0	512	100.00
Milho	0	0	0	0	768	0	0	0	0	512	0	0	0	1280	60.00
Cana1	0	0	0	0	0	512	0	0	0	0	0	0	0	512	100.00
Cana2	0	0	0	0	0	0	512	0	0	0	0	0	512	1024	50.00
Feijão1R	0	0	0	0	0	0	0	0	0	0	0	0	0	0	NaN
Feijao2R	0	0	0	0	0	0	0	0	0	0	0	0	0	0	NaN
SorgoR	0	0	0	0	0	0	0	0	0	0	0	0	0	0	NaN
MilhoR	0	0	0	0	0	0	0	0	0	0	768	0	0	768	100.00
Cana1R	0	0	0	0	0	0	0	0	0	0	0	512	0	512	100.00
Cana2R	0	0	0	0	0	0	0	0	0	0	0	0	0	0	NaN
Total	10240	128	640	512	768	512	512	128	640	512	768	512	512	16384	
acur. rel. %	100.00	100.00	100.00	100.00	100.00	100.00	100.00	0.00	0.00	0.00	100.00	100.00	0.00		
Acur. Global=0.89063 kappa=0.81632															

A Tabela 5.1 mostra a matriz de confusão de uma classificação híbrida, resultante da transformação nebulosa dos resultados de uma classificação obtida com a rede de Kohonen (seção 2.5.3). O objetivo deste procedimento é poder analisar a capacidade da Lógica Nebulosa em classificar séries bastante similares pelos seus respectivos graus de inclusão, resultantes de uma classificação supervisionada, treinada somente com as amostras das classes de interesse. Na Verdade Terrestre, as classes com ruído total menor que dez por cento foram consideradas classes novas, tendo acrescida ao nome da classe de origem a extensão 'R'. A classificação derivou-se de um mapa de Kohonen com seis nós, representantes das classes originais. A Lógica Nebulosa encarregou-se de separar as classes com ruído da seguinte forma: séries com grau de inclusão maior que 0.8 pertencem a classe, séries com grau entre 0.5 e 0.8

pertencem às respectivas classes com ruído e séries com grau menor 0.5 foram consideradas não classificadas.

Observa-se que cento e vinte oito pixels da classe Feijão1R (ruído menor que dez por cento), foram classificados como Feijão1. Isto se deve a ausência de amostras para séries em questão, tendo sido estas classificadas como pertencentes a classe original mais similar, com grau de inclusão 0.91. A Figura 5.1 mostra a grande similaridade entre estas classes, o que se leva a concluir intuitivamente, que estas séries devam pertencer à mesma classe, ou seja, a classe Feijão1.

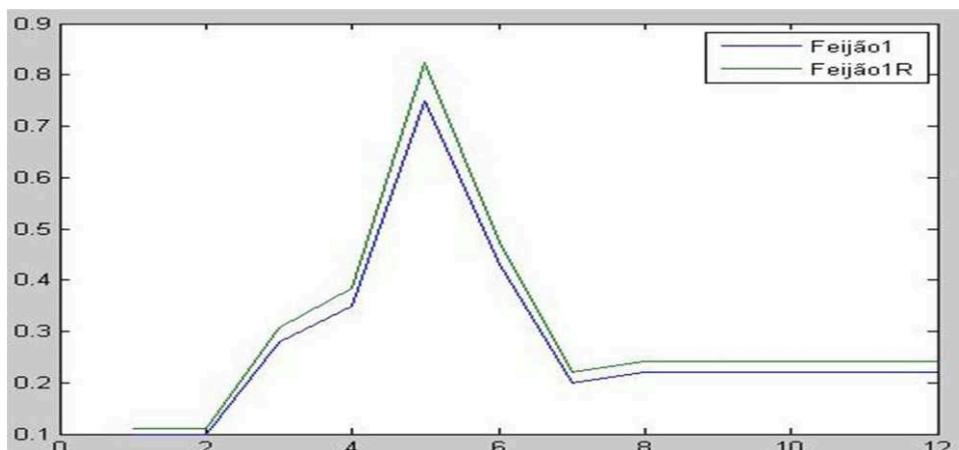


Figura 5.1 Perfis das Classes Feijão1 e Feijão1R

Outro fato importante é a atribuição de quinhentos e doze séries da classe SorgoR à classe Milho, porém ao observarmos a Figura 5.2, verificamos que realmente a classe SorgoR (Sorgo adicionada de ruído) se aproxima muito mais da classe Milho do que da classe Sorgo. As demais discrepâncias são explicáveis da mesma forma, ressaltando que as séries referentes à classe Feijão2 obtiveram grau de inclusão 0.86.

Desta forma, fica evidenciada a possibilidade de se discriminar as séries classificadas em uma mesma classe de acordo com seus respectivos graus de inclusão.

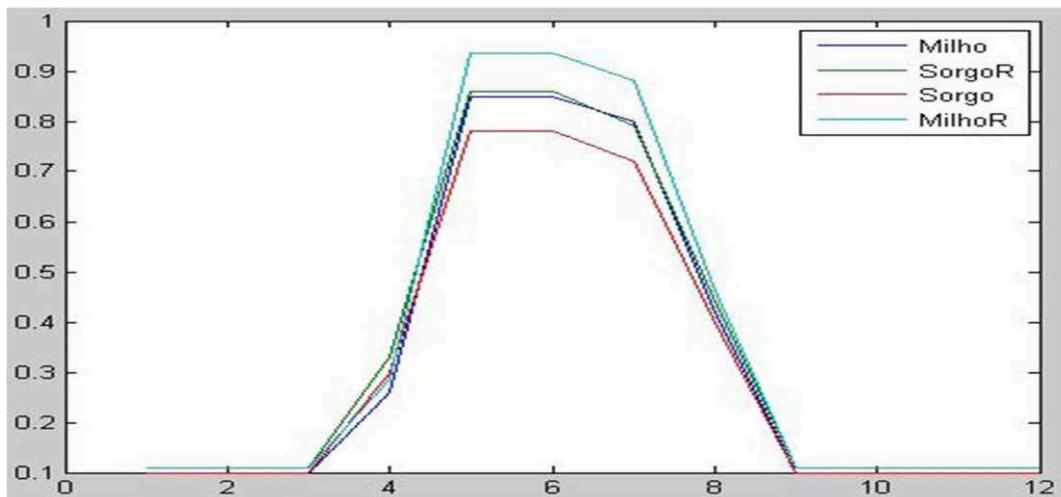


Figura 5.2 Perfis das Classes Milho e Sorgo (com e sem ruído)

A seguir uma nova classificação nebulosa é obtida simplesmente variando o grau de inclusão, para se avaliar a flexibilidade e robustez deste tipo de classificação. Para isto são geradas duas classificações com os graus de inclusão com limiares em 0.8 e 0.7 respectivamente. Na verdade Terrestre desta análise, as séries com percentual de ruído menor que dez são classificadas como pertencentes à classe original e as séries com ruído maior que 10 por cento são consideradas como não classificadas.

Tabela 5.2 Matriz de Confusão com grau de Inclusão com limiar em 0.8

	não class	Feijão1	Feijão2	Sorgo	Milho	Cana1	Cana2	Total	acur. rel. %
não class	11904	0	0	128	0	128	0	12160	97.89
Feijão1	0	768	0	0	0	0	0	768	100.00
Feijão2	0	0	1024	0	0	0	0	1024	100.00
Sorgo	0	0	0	512	0	0	0	512	100.00
Milho	0	0	0	0	896	0	0	896	100.00
Cana1	0	0	0	0	0	640	0	640	100.00
Cana2	0	0	0	0	0	0	384	384	100.00
Total	11904	768	1024	640	896	768	384	16384	
acur. rel. %	100.00	100.00	100.00	80.00	100.00	83.33	100.00		
Acur. Global=0.98438 kappa=0.96513									

A Tabela 5.2 mostra a matriz de confusão de uma classificação onde apenas as séries com grau de inclusão maior que 0.8 são consideradas como pertencentes à classe correspondente. Pode-se constatar que somente as séries muito similares entre

si foram atribuídas à mesma classe. Respalhando este fato, verificamos que 128 séries da classe sorgo com ruído de dez por cento e 128 séries da classe Cana1 também com o mesmo nível de ruído foram consideradas como não classificadas.

Tabela 5.3 Matriz de Confusão com grau de Inclusão com limiar em 0.7

	não class	Feijão1	Feijão2	Sorgo	Milho	Cana1	Cana2	Total	acur. rel. %
não class	11776	0	0	0	0	0	0	11776	100.00
Feijão1	128	768	0	0	0	0	0	896	85.71
Feijão2	0	0	1024	0	0	0	0	1024	100.00
Sorgo	0	0	0	512	0	0	0	512	100.00
Milho	0	0	0	128	896	0	0	1024	87.50
Cana1	0	0	0	0	0	768	0	768	100.00
Cana2	0	0	0	0	0	0	384	384	100.00
Total	11904	768	1024	640	896	768	384	16384	
acur. rel. %	98.92	100.00	100.00	80.00	100.00	100.00	100.00		
Acur. Global=0.98438 kappa=0.96632									

Na matriz de confusão da classificação que considera o grau de inclusão com limiar em 0.7, exibida na Tabela 5.3, verificamos que as séries correspondentes a Cana1 com ruído são classificadas como pertencentes à respectiva classe, enquanto que as 128 séries relacionadas como Sorgo na verdade terrestre e não classificadas na classificação de limiar em 0.8 são classificadas como Milho nesta abordagem. Este fato, como já explicado anteriormente, se deve ao perfil da série sorgo com ruído se assemelhar bem mais a assinatura temporal da classe Milho; como pode ser visto na Figura 5.2. Nota-se, também, que 128 séries da classe Feijão1 com ruído que anteriormente não haviam sido classificadas, são classificadas como pertencentes à classe Feijão1, quando se considera um limiar menos rigoroso para o grau de inclusão. A Figura 5.3 mostra os perfis temporais destas duas classes.

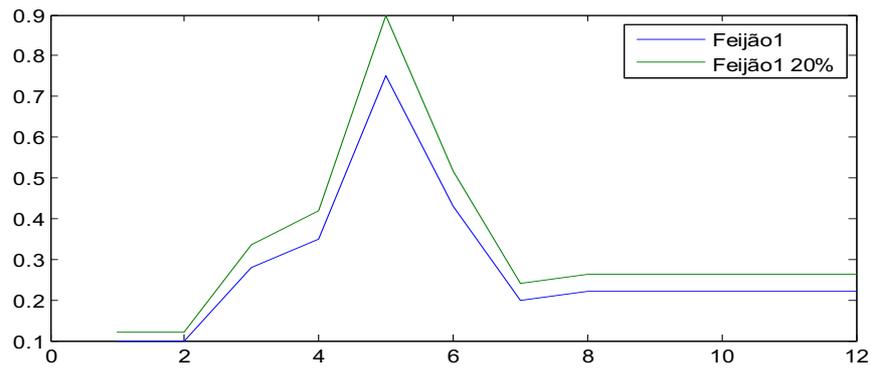


Figura 5.3 Perfis das Classes Feijão1 e Feijão1 com Ruído de 20%

Uma nova experiência foi realizada com a aplicação do sistema ANFIS aos mesmos dados dos experimentos anteriores, com os resultados mostrados na Tabela 5.4. Novamente, devido a razões já explicadas anteriormente, as séries de Sorgo com ruído de dez por cento são atribuídas à classe Milho.

Tabela 5.4 Matriz de Confusão de uma Classificação com o sistema ANFIS

	não class	Feijão1	Feijão2	Sorgo	Milho	Cana1	Cana2	Total	acur. rel. %
não class	11904	0	0	0	0	0	0	11904	100.00
Feijão1	0	768	0	0	0	0	0	768	100.00
Feijão2	0	0	1024	0	0	0	0	1024	100.00
Sorgo	0	0	0	512	0	0	0	512	100.00
Milho	0	0	0	128	896	0	0	1024	87.50
Cana1	0	0	0	0	0	768	0	768	100.00
Cana2	0	0	0	0	0	0	384	384	100.00
Total	11904	768	1024	640	896	768	384	16384	
acur. rel. %	100.00	100.00	100.00	80.00	100.00	100.00	100.00		
Acur. Global=0.99219 kappa=0.98297									

Ressalva-se que, até o momento, a metodologia tem sido aplicada parcialmente, já que as amostras de treinamento das classes de interesse são compostas pelo representante de cada classe original (sem ruído) não levando em conta a fase de seleção das amostras, na qual os perfis representativos de cada classe são determinados por agrupamentos.

Finalmente, os procedimentos metodológicos sugeridos são aplicados na íntegra, inclusive com a fase de seleção das amostras, aos dados em questão. Os

resultados desta abordagem podem ser analisados na Tabela 5.5. As séries de Sorgo com ruído, classificadas como Milho nas abordagens precedentes, desta vez foram classificadas como Sorgo de acordo com a verdade terrestre, isto se deve a detecção pela metodologia da necessidade de um representante para a classe Sorgo com ruído, incluindo o perfil temporal desta classe as amostras de treinamento e associando-o a classe Sorgo, segundo a verdade terrestre.

Tabela 5.5 Classificação com o Sistema ANFIS considerando amostra de Sorgo com ruído

	não class	Feijão1	Feijão2	Sorgo	Milho	Cana1	Cana2	Total	acur. rel. %
não class	11904	0	0	0	0	0	0	11904	100.00
Feijão1	0	768	0	0	0	0	0	768	100.00
Feijão2	0	0	1024	0	0	0	0	1024	100.00
Sorgo	0	0	0	640	0	0	0	640	100.00
Milho	0	0	0	0	896	0	0	896	100.00
Cana1	0	0	0	0	0	768	0	768	100.00
Cana2	0	0	0	0	0	0	384	384	100.00
Total	11904	768	1024	640	896	768	384	16384	33
acur. rel. %	100.00	100.00	100.00	100.00	100.00	100.00	100.00	88.11	90.91
Acur. Global=1 kappa=1									

As experiências com dados simulados objetivaram analisar de forma isolada as diversas técnicas que compõem a metodologia, através de dados controlados e conhecidos, sem a inconsistência de séries excessivamente ruidosas e verdades terrestres imprecisas que atrapalhariam este tipo de análise. Como podemos constatar, em relação a esta avaliação, a metodologia se mostrou eficiente e promissora.

5.2 Estudo de Caso com Dados Reais

Este estudo visa à análise dos procedimentos metodológicos com dados oriundos do sensor MODIS. Da mesma forma que, no trabalho com dados simulados,

este experimento terá duas abordagens, uma com mapa de Kohonen e outra com o sistema ANFIS.

5.2.1 Materiais

Para a realização desta experiência foi necessário a obtenção, no site da USGS (DAAC, 2006), de dois conjuntos do produto MOD13Q1 correspondentes cada um a 24 datas relativas aos anos de 2005 e 2006, um conjunto de dados de referência para o ano de 2005, de uma classificação da região em questão para o ano de 2006. Os dados para referência e classificação foram fornecidos pela Embrapa, baseados na pesquisa de Arvour (ARVOR; JONATHAN; MEIRELLES *et al.*, 2008). O estudo de Arvour está relacionado ao projeto ENVIAIR, e consiste no levantamento agrícola da região em análise, baseado em um trabalho de campo, no qual foram identificadas as seguintes espécies de culturas: Soja, Soja e Milheto, Soja e Brachiaria, Soja e Milho, Algodão, Milheto e Algodão, Cana, Arroz, e Pastagem (JONATHAN; MEIRELLES; BERROIR *et al.*, 2007; MEIRELLES; JONATHAN; FERRAZ *et al.*, 2007). A Figura 5.4 ilustra este levantamento.

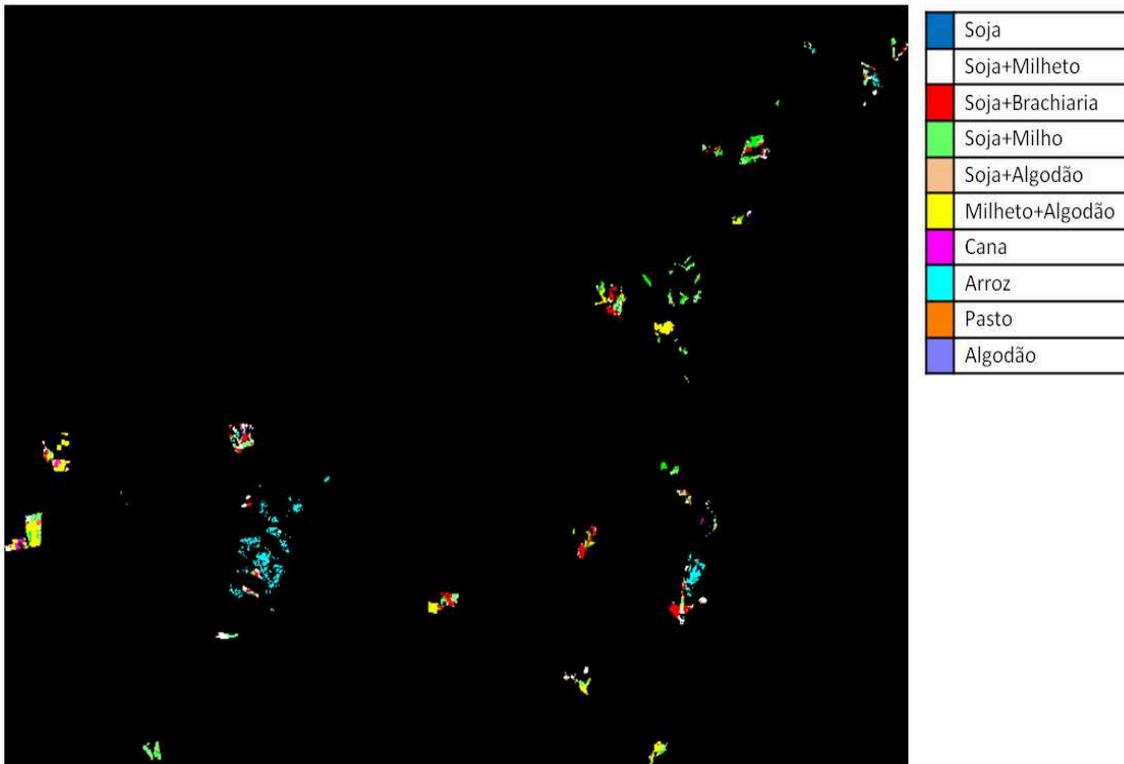


Figura 5.4 Levantamento de campo

Apesar de a metodologia ser aplicável a qualquer série temporal, optou-se, neste trabalho, por perfis temporais agrícolas, com alguns destes perfis representando duas espécies de agriculturas cultivadas consecutivamente. Este fato, além de ter aumentado a similaridade entre as classes robusteceu a análise da metodologia, principalmente no concernente à Transformada *Wavelet*, visto que em séries com dupla informação, nas quais somente uma das culturas varia, a informação temporal se diferencia em um curto espaço no tempo, e à Lógica Nebulosa, devido à grande semelhança entre séries representativas de duas culturas.

A área de estudo (Figura 5.5) é uma região do Estado do Mato Grosso, delimitado pelas coordenadas ($11^{\circ}49'35.24''S$ $58^{\circ}58'35.98''W$; $14^{\circ}30'57.22''S$ $55^{\circ}6'36.84''W$), compreendendo uma extensão de $124.831,6875 \text{ km}^2$. Caracterizada pela policultura de grãos e da cana de açúcar.

A área de análise compreende a 1997307 pontos, enquanto a quantidade total de dados analisados corresponde a 47935368 pontos.



Figura 5.5 Estado Mato Grosso com a Área de Estudo Representada no Retângulo Escuro

Os dados, para o ano de 2005, serão utilizados no levantamento das amostras de treinamento e os de 2006 para a classificação propriamente dita.

5.2.2 Aplicação da metodologia e avaliação

Diferentemente da abordagem com dados simulados, na qual alguns procedimentos não se fizeram necessários, esta análise fará uso de todas as fases da metodologia.

Inicialmente os dados foram adquiridos do site da NASA (NASA,2006), e como descrito na metodologia, foram convertidos para a projeção UTM e para o formato 'geotif'.

A fase de pré-processamento foi aplicada ao conjunto de imagens dos dois anos, a fim de obter perfis comparáveis de ambas as datas.

Em seguida aplicou-se a Transformada *Wavelet* (seção 2.4) a todo conjunto de dados, reduzindo a dimensionalidade destes dados à metade.

A etapa de seleção das amostras foi aplicada sobre o conjunto de dados e referencia do ano 2005. Obtendo-se então os representantes de cada classe. A Tabela 5.6 relaciona a quantidade de perfis encontrados para as classes de interesse.

Tabela 5.6 Quantidade de Perfis Para as Classes de Interesse

Soja	Soja + Milheto	Soja + Brachiaria	Soja + Milho	Algodão	Algodão +Milheto	Cana	Arroz	Pasto
8	10	10	12	6	5	10	4	6

Assim sendo, uma rede de Kohonen (seção 2.5.3) foi treinada, tendo como pesos iniciais os perfis relacionados na fase de seleção de amostras.

As séries correspondentes ao ano de 2006 foram então divididas em ladrilhos de largura e altura iguais a 64 *pixels*, conforme explicado na metodologia. Esse procedimento foi adotado para tornar a sua aplicação independente da plataforma disponível.

Em seguida, as séries da área em estudo foram classificadas através da rede projetada anteriormente, transformando-se os resultados obtidos em nebulosos, com isto foi obtida uma classificação flexível e a separação das classes desconhecidas pela Lógica Nebulosa. Obteve-se, assim como descrito na metodologia, os perfis temporais das classes não conhecidas, para serem utilizadas no sistema ANFIS (seção 2.7.1).

Finalmente, uma classificação da mesma massa de dados também foi gerada com o sistema ANFIS e calculada a matriz de confusão (seção 2.8.2.1), o Coeficiente 'Kappa' (seção 2.8.2.1) e as acurácias desejadas.

Constatou-se que o aumento da massa de dados e do número de amostras não afetam a qualidade da classificação, acarretando apenas um aumento linear do tempo de processamento na fase de seleção das amostras.

Apesar da breve explanação sobre a aplicação da metodologia, ressalta-se que os resultados foram alcançados de forma automática, sem a necessidade de qualquer interferência durante as fases do processo.

Na análise dos resultados, uma das preocupações foi constatar a influência do uso dos coeficientes *wavelets* (seção 2.4) em detrimento dos dados originais na classificação, para tanto foram geradas duas classificações para as diferentes bases de dados com a rede de Kohonen, cujos resultados podemos observar na Tabela 5.7 e na Tabela 5.8. É interessante perceber a insignificante diferença entre os resultados das

duas classificações, bem como um Coeficiente 'Kappa' de aproximadamente 0.86, constatando uma classificação eficiente com a rede de Kohonen.

Tabela 5.7 Classificação com Coeficientes Wavelet

	Soja	Soja+Milhe	Soja+Brach	Soja+Milho	Soja+Algod	Milheto+Alc	Cana	Arroz	Pasto	Algodão	Total	acur. rel. %
Soja	1940	189	7	62	0	0	23	0	0	0	2221	87.35
Soja+Milhel	147	2448	7	307	1	0	24	0	0	0	2934	83.44
Soja+Brach	1	5	1368	515	94	0	1	0	0	0	1984	68.95
Soja+Milho	35	147	109	2719	16	0	11	0	0	0	3037	89.53
Soja+Algod	0	0	78	16	2980	4	0	0	0	0	3078	96.82
Milheto+Alc	0	0	1	2	129	400	4	0	0	37	573	69.81
Cana	35	13	1	10	2	2	2918	0	0	3	2984	97.79
Arroz	0	0	0	0	0	0	0	33	0	0	33	100.00
Pasto	0	2	1	1	0	0	5	0	45	0	54	83.33
Algodão	2	0	0	0	0	14	26	0	0	656	698	93.98
Total	2160	2804	1572	3632	3222	420	3012	33	45	696	17596	
acur. rel. %	89.81	87.30	87.02	74.86	92.49	95.24	96.88	100.00	100.00	94.25	79.89	
Acur. Global=0.88128 kappa=0.86013												

Tabela 5.8 Classificação com Dados Originais

	Soja	Soja+Milhe	Soja+Brach	Soja+Milho	Soja+Algod	Milheto+Alc	Cana	Arroz	Pasto	Algodão	Total	acur. rel. %
Soja	1954	176	3	34	0	0	18	0	0	0	2185	89.43
Soja+Milhel	106	2453	16	263	1	0	17	0	0	0	2856	85.89
Soja+Brach	7	4	1356	499	115	0	0	0	0	0	1981	68.45
Soja+Milho	46	155	101	2804	18	0	14	0	0	0	3138	89.36
Soja+Algod	0	0	95	19	2980	4	1	0	0	0	3099	96.16
Milheto+Alc	0	0	1	1	106	393	18	0	0	20	539	72.91
Cana	47	15	0	12	2	0	2926	0	0	7	3009	97.24
Arroz	0	0	0	0	0	0	0	33	0	0	33	100.00
Pasto	0	1	0	0	0	0	7	0	45	0	53	84.91
Algodão	0	0	0	0	0	23	11	0	0	669	703	95.16
Total	2160	2804	1572	3632	3222	420	3012	33	45	696	17596	
acur. rel. %	90.46	87.48	86.26	77.20	92.49	93.57	97.14	100.00	100.00	96.12	79.89	
Acur. Global=0.8873 kappa=0.86713												

Com relação à geração automática de regras, o sistema ANFIS (seção 2.7.1) proporcionou uma boa classificação, com um Coeficiente Kappa de 0.76, baseada em

suas regras geradas automaticamente, como visto na Tabela 5.9. Vale frisar que nesta classificação somente foram utilizadas as regras geradas de forma automática, sem nenhuma alteração ou acréscimo de novas regras.

Tabela 5.9 Classificação com o Sistema ANFIS com Regras automáticas

	Soja	Soja+Milhe	Soja+Brach	Soja+Milho	Soja+Algod	Milheto+Alg	Cana	Arroz	Pasto	Algodão	Total	acur. rel. %
Soja	1871	206	3	14	0	0	4	0	0	0	2098	89.18
Soja+Milhet	189	2277	24	204	0	5	12	0	0	1	2712	83.96
Soja+Brach	32	225	1165	828	59	4	13	0	0	0	2326	50.09
Soja+Milho	22	74	305	2487	237	4	18	0	0	0	3147	79.03
Soja+Algod	6	6	71	80	2570	10	16	0	0	0	2759	93.15
Milheto+Alg	7	5	2	4	339	332	176	0	0	9	874	37.99
Cana	22	9	1	11	15	38	2557	0	0	10	2663	96.02
Arroz	9	0	0	2	0	5	182	32	0	13	243	13.17
Pasto	2	2	1	1	0	3	20	1	44	63	137	32.12
Algodão	0	0	0	1	2	19	14	0	1	600	637	94.19
Total	2160	2804	1572	3632	3222	420	3012	33	45	696	17596	
acur. rel. %	86.62	81.21	74.11	68.47	79.76	79.05	84.89	96.97	97.78	86.21	79.89	
Acur. Global=0.79194 kappa=0.7566												

Com o intuito de se verificar a flexibilidade do sistema, foi adicionada ao conjunto de regras geradas automaticamente, uma nova regra considerando simplesmente o NDVI máximo de cada classe, alcançando com isto uma melhora na classificação, com um novo Coeficiente Kappa de 0.81, como pode ser observado na Tabela 5.10. Mostrando o potencial do sistema ANFIS, quando adiciona-se novas regras específicas do contexto analisado.

Tabela 5.10 Classificação com o sistema ANFIS com adição de regra

	Soja	Soja+Milhe	Soja+Brach	Soja+Milho	Soja+Algod	Milheto+Alç	Cana	Arroz	Pasto	Algodão	Total	acur. rel. %
Soja	1949	204	1	59	0	0	32	0	0	0	2245	86.82
Soja+Milhet	121	2444	5	247	0	0	24	0	0	0	2841	86.03
Soja+Brach	13	1	1358	511	169	0	1	0	0	0	2053	66.15
Soja+Milho	37	139	168	2793	7	0	6	0	0	0	3150	88.67
Soja+Algod	0	0	36	3	2690	23	0	0	0	1	2753	97.71
Milheto+Alç	7	5	2	4	339	332	176	0	0	9	874	37.99
Cana	22	9	1	11	15	38	2557	0	0	10	2663	96.02
Arroz	9	0	0	2	0	5	182	32	0	13	243	13.17
Pasto	2	2	1	1	0	3	20	1	44	63	137	32.12
Algodão	0	0	0	1	2	19	14	0	1	600	637	94.19
Total	2160	2804	1572	3632	3222	420	3012	33	45	696	17596	
acur. rel. %	90.23	87.16	86.39	76.90	83.49	79.05	84.89	96.97	97.78	86.21	79.89	
Acur. Global=0.84104 kappa=0.81387												

As classificações alcançadas foram realizadas sobre todas as classes de interesse, inclusive sobre classes bastante similares como Soja, Soja e Milheto, Soja e Brachiaria, e Soja e Milho, que normalmente seriam agrupadas em uma única classe em trabalhos similares. Visando analisar o comportamento da metodologia com este tipo de análise, estas classes foram consideradas pertencentes a uma única classe e duas novas classificações com as abordagens propostas foram geradas para esta situação, com os resultados sendo mostrados na Tabela 5.11 e na Tabela 5.12. Nestas, podem-se visualizar na matriz de cima os resultados da união das classes Soja em uma única classe, e na matriz abaixo, além da junção das classes Soja, a união das classes de algodão, percebendo-se uma sensível melhora na classificação, quando classes poucos discrimináveis se agrupam em uma única classe.

Tabela 5.11 Classificação usando Kohonen com união de classes

	Soja	Milheto+Alç	Cana	Arroz	Pasto	Algodão	Total	acur. rel. %
Soja	13191	4	59	0	0	0	13254	99.52
Milheto+Alç	132	400	4	0	0	37	573	69.81
Cana	61	2	2918	0	0	3	2984	97.79
Arroz	0	0	0	33	0	0	33	100.00
Pasto	4	0	5	0	45	0	54	83.33
Algodão	2	14	26	0	0	656	698	93.98
Total	13390	420	3012	33	45	696	17596	
acur. rel. %	98.51	95.24	96.88	100.00	100.00	94.25		
Acur. Global=0.97994 kappa=0.94927								

	Soja	Cana	Arroz	Pasto	Algodão	Total	acur. rel. %
Soja	13191	59	0	0	4	13254	99.52
Cana	61	2918	0	0	5	2984	97.79
Arroz	0	0	33	0	0	33	100.00
Pasto	4	5	0	45	0	54	83.33
Algodão	134	30	0	0	1107	1271	87.10
Total	13390	3012	33	45	1116	17596	
acur. rel. %	98.51	96.88	100.00	100.00	99.19	85.29	
Acur. Global=0.98284 kappa=0.95635							

Tabela 5.12 Classificação usando o sistema ANFIS com União de Classes

	Soja	Milheto+Alç	Cana	Arroz	Pasto	Algodão	Total	acur. rel. %
Soja	12955	23	63	0	0	1	13042	99.33
Milheto+Alç	357	332	176	0	0	9	874	37.99
Cana	58	38	2557	0	0	10	2663	96.02
Arroz	11	5	182	32	0	13	243	13.17
Pasto	6	3	20	1	44	63	137	32.12
Algodão	3	19	14	0	1	600	637	94.19
Total	13390	420	3012	33	45	696	17596	
acur. rel. %	96.75	79.05	84.89	96.97	97.78	86.21		
Acur. Global=0.93885 kappa=0.8499								

	Soja	Cana	Arroz	Pasto	Algodão	Total	acur. rel. %
Soja	12955	63	0	0	24	13042	99.33
Cana	58	2557	0	0	48	2663	96.02
Arroz	11	182	32	0	18	243	13.17
Pasto	6	20	1	44	66	137	32.12
Algodão	360	190	0	1	960	1511	63.53
Total	13390	3012	33	45	1116	17596	
acur. rel. %	96.75	84.89	96.97	97.78	86.02		
Acur. Global=0.94044 kappa=0.85279							

A união de classes de alta similaridade, como as variações de soja e algodão, também foi útil na análise através da Lógica Nebulosa, pois o uso da Lógica Nebulosa para classificação de uma grande quantidade de classes muito similares redundam em graus de inclusão de valores muito baixos e próximos entre si. Isto se deve à distribuição destes graus entre as classes objeto da análise, dificultando a interpretação dos resultados. Desta forma, a união de classes muito semelhantes como as diversas classes de soja e algodão, torna os valores dos graus de inclusão bem mais significativos. Outro fato a se considerar nesta abordagem é que cada classe possui vários representantes, de forma que na transformação nebulosa devemos considerar para o cálculo dos graus de inclusão de cada série o seu respectivo representante, já que cada classe pode possuir vários representantes.

A Tabela 5.13 mostra a matriz de confusão de uma classificação Nebulosa na qual as diferentes classes de soja (soja, soja e milheto, soja e brachiaria, soja e milho) e algodão (algodão, algodão e milheto) compuseram, respectivamente, uma única classe. Nesta abordagem consideraram-se como pertencentes a uma determinada classe, todas as séries com o maior grau de inclusão, semelhando-se a uma classificação clássica. Deve-se observar os ótimos resultados obtidos.

Tabela 5.13 Classificação Nebulosa Considerando o Maior Grau de Inclusão

	Soja	Cana	Arroz	Pasto	Algodão	Total	acur. rel. %
Soja	13191	59	0	0	4	13254	99.52
Cana	61	2918	0	0	5	2984	97.79
Arroz	0	0	33	0	0	33	100.00
Pasto	4	5	0	45	0	54	83.33
Algodão	134	30	0	0	1107	1271	87.10
Total	13390	3012	33	45	1116	17596	
acur. rel. %	98.51	96.88	100.00	100.00	99.19	85.29	
Acur. Global=0.98284 kappa=0.95635							

Os resultados podem ser ainda melhores se considerarmos, como integrantes de uma determinada classe, somente as séries com um grau de certeza razoável para uma determinada classe. A Tabela 5.14 possibilita esta constatação, exibindo os

resultados de uma classificação, em que são consideradas somente as classes com grau de inclusão maior que 0.6 para a mesma massa de dados da classificação anterior.

Tabela 5.14 Classificação Nebulosa Considerando Grau de Inclusão Maior que 0.6

	Soja	Cana	Arroz	Pasto	Algodão	Total	acur. rel. %
Soja	11720	3	0	0	0	11723	99.97
Cana	2	1927	0	0	1	1930	99.84
Arroz	0	0	33	0	0	33	100.00
Pasto	0	0	0	45	0	45	100.00
Algodão	30	1	0	0	1046	1077	97.12
Total	11752	1931	33	45	1047	14808	
acur. rel. %	99.73	99.79	100.00	100.00	99.90	85.29	
Acur. Global=0.9975 kappa=0.99285							

Podemos ver na Tabela 5.15 uma classificação nebulosa, ainda mais rigorosa, quanto ao grau de semelhança entre as séries e suas respectivas classes, considerando para isto um grau de inclusão maior que 0.8. Essa abordagem classifica somente as séries com um alto grau de certeza para fazerem parte de uma determinada classe. Verificamos também nessa abordagem um alto grau de acerto, com Kappa=0.99.

Tabela 5.15 Classificação Nebulosa Considerando Grau de Inclusão Maior que 0.8

	Soja	Cana	Arroz	Pasto	Algodão	Total	acur. rel. %
Soja	5365	1	0	0	0	5366	99.98
Cana	0	354	0	0	0	354	100.00
Arroz	0	0	33	0	0	33	100.00
Pasto	0	0	0	44	0	44	100.00
Algodão	3	0	0	0	824	827	99.64
Total	5368	355	33	44	824	6624	
acur. rel. %	99.94	99.72	100.00	100.00	100.00		
Acur. Global=0.9994 kappa=0.99814							

O acerto total não foi alcançado devido a uma inconsistência na verdade terrestre, visto que na Figura 5.6 podemos observar que a série classificada como soja, e que na verdade terrestre pertence à classe cana, se assemelha muito mais a o perfil temporal da soja do que ao da cana. Na Figura 5.7 constatamos que as três séries

classificadas como algodão, pertencendo à classe soja na verdade terrestre, possuem realmente uma maior identificação com a classe algodão.

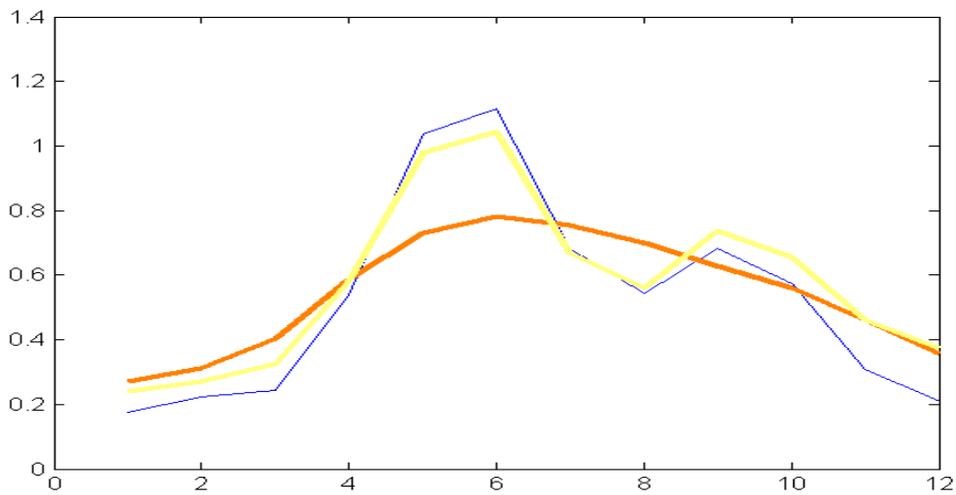


Figura 5.6 As linhas mais Grossas Representam as Amostras de Cana em Laranja e Soja em Amarelo, as Linhas mais Finas as Séries Classificadas

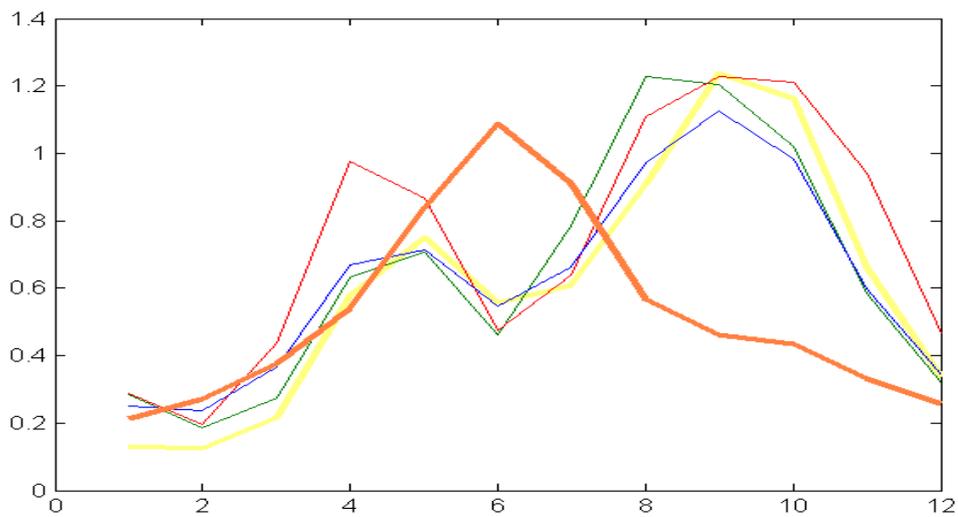


Figura 5.7 As Linhas mais Grossas Representam as Amostras de Algodão em Laranja e Soja em Amarelo, as Linhas mais Finas as Séries Classificadas

A Figura 5.8 mostra o resultado final de uma classificação realizada com a metodologia.

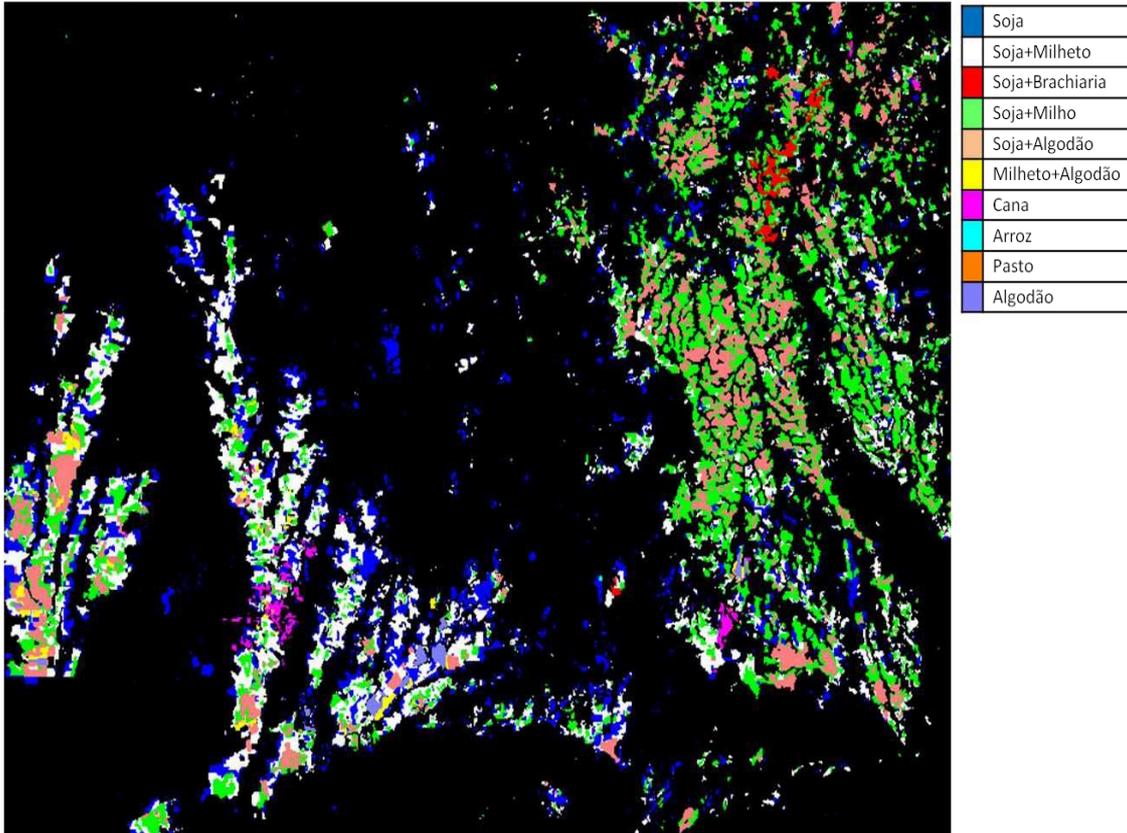


Figura 5.8 Mapa das Classes Agrícolas

Nesta análise, a utilização de perfis temporais com dupla assinatura mostrou-se providencial na avaliação da capacidade da metodologia em discernir classes muito similares. O sistema ANFIS mostrou sua capacidade evolutiva ao acrescentarem-se novas regras as determinadas automaticamente. Pôde-se observar uma maior flexibilidade da classificação com a utilização da Lógica Nebulosa, permitindo-se variar o grau de certeza de uma classificação, promovendo assim um aumento da acurácia e até mesmo uma classificação nebulosa, na qual o grau de inclusão das respectivas séries temporais determinaria a possibilidade de pertencerem às suas classes correspondentes.

6 Conclusões

6.1 Dados Simulados

Embora os dados simulados não possam ser comparados à complexidade dos dados reais, os experimentos realizados com este tipo de dados possibilitaram uma avaliação controlada das diversas fases da metodologia.

Com relação à Lógica Nebulosa, constatou-se o seu potencial para obtenção de classificações mais flexíveis, nas quais se possam estabelecer o rigor desejado e graus de inclusão, avaliando a tendência de cada pixel pertencer a uma determinada categoria, além de prover um tratamento à mistura de classes e possibilitar a discriminação das séries não determinadas pelas amostras das classes de interesse.

Essas experiências também mostram a importância da escolha correta dos representantes que compõem as amostras e a capacidade da fase de seleção das amostras em realizar tal tarefa, pois verificamos que, devido à alta sensibilidade das técnicas utilizadas, a qualidade de uma classificação pode variar substancialmente pela inclusão ou retirada de um determinado perfil temporal das amostras de treinamento.

Podemos confirmar que a Transformada *Wavelet* permitiu o agrupamento e classificação das séries temporais, reduzindo a dimensionalidade dos dados à metade com uma perda insignificante de informação e mantendo a qualidade dos resultados dos dados originais.

O sistema ANFIS e a rede de Kohonen se mostraram capazes de realizarem classificações eficientes, desde que treinadas adequadamente.

Segundo esta análise, a metodologia se mostrou aplicável a séries temporais do sensor MODIS com uma promissora capacidade de classificar os seus dados.

6.2 Dados Reais

A fase de pré-processamento (seção 2.3) se mostrou fundamental para a correção de distorções, que aumentariam bastante a dificuldade para a classificação

de algumas séries. O filtro de qualidade dos dados possibilitou a exclusão de datas com NDVI (seção 2.1.2) de baixa qualidade, comprometido pelo excesso de nuvens ou outras variáveis. Com relação aos filtros de média e desvio padrão, o segundo se mostrou mais eficaz, resultando em perfis mais suaves quando comparado aos originais, facilitando dessa forma a associação destes perfis com suas respectivas amostras.

A conversão de projeção e de formato de arquivo não só facilitaram as etapas subseqüentes como também facilitaram o acesso aos dados de forma geral, tornando-os independentes de mecanismos pouco usuais.

A Transformada *Wavelet* (seção 2.4) reduziu a dimensionalidade dos dados, sem perdas importantes, preservando a informação de tempo de todas as datas consideradas.

Esta diminuição tornou sensivelmente mais rápida as fases de seleção de amostras e treinamento das redes envolvidas.

O nível 1 da transformada de Daubechies de ordem 1 foi preferido, devido à intenção de se discriminar classes com alto grau de similaridade, mas para classes menos semelhantes entre si poderia se estudar outros níveis, diminuindo ainda mais a dimensão das séries temporais.

A etapa da seleção das amostras apresentou-se eficiente na escolha automática dos representantes de cada classe, escolhendo-os de acordo com sua variação no tempo e nos valores de NDVI. A escolha do raio de influência para estimativa do número de grupos se mostrou mais intuitiva que a escolha direta da quantidade de grupos, pois possibilita o estabelecimento de um grau de exigência correspondente à complexidade do conjunto de dados em análise, obtendo-se, desta forma, através do algoritmo '*Subtractive Clustering*' (seção 2.8.1) uma boa estimativa do número de grupos iniciais.

Pode-se considerar que as amostras selecionadas nesta fase foram fundamentais para a qualidade do treinamento da rede auto organizável e do sistema ANFIS.

A divisão dos dados em ladrilhos acrescentou flexibilidade e agilidade à metodologia, propiciando a sua execução desde plataformas com poucos recursos até ambientes mais robustos (uma rede computadores) com o máximo de aproveitamento dos recursos disponíveis em ambas as situações. Essa divisão também possibilitou uma programação matricial com todos os dados na memória, aumentando substancialmente a velocidade de processamento.

Com relação à classificação, a rede de Kohonen apesar de classificar melhor os dados com menor semelhança, pois ao analisarmos as matrizes de confusão verificamos que as classes que tiveram maiores problemas foram as séries de grande similaridade, mostrou potencial para discriminar séries temporais com alta similaridade, pois mesmo estas séries obtiveram um bom índice de classificação, com a rede identificando pequenas variações no tempo e no NDVI (amplitude), para o conjunto de dados em questão.

A Lógica Nebulosa (seção 2.6) acrescentou flexibilidade à classificação do mapa de Kohonen, possibilitando uma classificação com maior ou menor rigor de acordo com as necessidades da classificação. Devido ao grande número de classes envolvidas na classificação, para uma melhor interpretação dos resultados foi necessário o agrupamento das classes muito similares em um único grupo, e posteriormente uma realização de uma nova análise específica para este grupo. Como cada classe pode possuir várias amostras, também, foi necessária a associação de cada série com a sua respectiva amostra. Sugerindo-se, desta forma, que para uma grande quantidade de classes muito similares é desejável uma redução destas classes para uma melhor análise dos graus de inclusão.

O sistema ANFIS (seção 2.7.1), embora não tenha apresentado o mesmo desempenho que a rede de Kohonen (seção 2.5.3), também alcançou uma boa classificação, levando-se em conta o modelo gerado automaticamente. O acréscimo de uma nova regra melhorou os resultados da classificação, mostrando a capacidade do sistema ANFIS aliado a um conjunto de regras que representem as características dos dados em análise, como: dados históricos, época de plantio, valores máximos, umidade, etc.; evoluir para um sistema especialista, baseado em regras nebulosas, de alto desempenho.

Embora o sensor MODIS (seção 2.2) apresente uma restrição quanto a sua resolução espacial, para o caso de países como o Brasil onde o tamanho das classes é maior que a resolução do sensor, este fato pode ser considerado uma vantagem, pois minimiza o tamanho da massa de dados a ser processada. Portanto, as séries temporais do sensor MODIS se revelaram uma alternativa de baixo custo para a classificação em larga escala de classes que apresentam uma variação de suas características ao longo do tempo.

O uso do NDVI (seção 2.2.1) do sensor MODIS atendeu as necessidades das classificações, apresentando maior dificuldade de discriminação em classes com assinaturas espectrais duplas e muito similares, o que poderia ser mais bem resolvido com acréscimo de mais informações, adequando-se, assim, ao sistema ANFIS.

A fase de pós-processamento (seção 2.3), realizada através do filtro descrito na metodologia (seção 4), eliminou alguns *pixels* isolados, principalmente nas classes compostas de Soja com outra cultura, proporcionando, desta forma, uma maior suavidade aos mapas resultantes.

Apesar de limitações como: moderada resolução espacial devido ao sensor e a necessidade de amostras, de forma geral, a metodologia mostrou um bom desempenho, indicando ser uma alternativa viável para os dados considerados.

6.3 Trabalhos futuros

Com relação aos trabalhos futuros pode-se sugerir: o uso de dados de refletância no lugar do NDVI, o uso de refletância em conjunto com o NDVI a fim de se melhorar a classificação, a alteração das regras geradas pelo sistema ANFIS de modo a se obter melhores resultados, e, até mesmo, a classificação de novas coberturas do solo apesar da moderada resolução do sensor utilizado.

Outro trabalho interessante é o desenvolvimento de um *Workflow* que automatize os procedimentos propostos e a migração dos algoritmos desenvolvidos neste trabalho para um *Grid Computacional*, objetivando-se uma melhora do desempenho da metodologia proposta e automação de todo o processo, inclusive das diferentes abordagens, agilizando e facilitando o uso da metodologia a um número maior de usuários.

Referências

ACHARYA, T. ; RAY, A. K. **Image processing: principles and applications**. Hoboken: Wiley - Interscience, 2005.

ANDERSON, L. O. **Classificação e monitoramento da cobertura vegetal do estado do Mato Grosso utilizando dados multitemporais do sensor MODIS. 2005**

Dissertação(Mestrado em Sensoriamento Remoto) - Instituto Nacional de Pesquisas Espaciais, São Jose dos Campos, 2005.

ARGOUD, F. I. M. ; AZEVEDO, F. M. ; MARINO NETO, J. Estudo comparativo entre funções wavelet e suas diferentes aplicabilidades em reconhecimento de padrões epileptogênicos em eletroencefalograma. **Revista Brasileira de Engenharia Biomédica: Campinas**, v.20, n.2/3, p. 49-59, dez. 2004.

ARVOR, D. et al. Comparison of multitemporal MODIS-EVI smoothing algorithms and its contribution to crop monitoring. In: IEEE GEOSCIENCE & REMOTE SENSING SYMPOSIUM: I2008, Boston. **Proceedings ... Boston**, 2008. p. 958-961 p.

ASSIS, V. D. C. D. D. **Uso de mapas auto-organizáveis de Kohonen em classificação de padrões**. Dissertação (Mestrado em Ciência da Computação) — Universidade Federal da Bahia, Salvador.

BENEDETTI, R. ; ROSSINI, P. On the use of NDVI profiles as a tool for agricultural statistics: the case study wheat yield estimate and forecast in Emilia Romagna. **Remote Sensing of Environment**, Amsterdam, v.45, n. 3, p. 311-326, 1993.

BEZDEK, J. **Pattern recognition with fuzzy objective function algorithm**. New York: Plenum Press, 1981.

BRAGA, A. ; CARVALHO, A. ; LUDERMIR, T. **Redes neurais artificiais: teoria e aplicações**. Rio de Janeiro: Livros Técnicos e Científicos, 2000.

BULTHEEL, A. **Wavelets with applications in signal and image processing**, 2003

CCRS.**Outreach materials**.(2006). Disponível em:

<http://ccrs.nrcan.gc.ca/resource/index_e.php>. Acesso em: 2007.

CANAVESI, V. et al. Dinâmica espectro-temporal MODIS em região de Cerrados e intenso uso agropecuário. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 12., 2005, Goiânia. **Anais ...** Goiânia: INPE, 2005. p. 1435-1442.

CARLANTONIO, L. M. D. **Novas metodologias para clusterização de dados**. 2001. Dissertação (Mestrado em Engenharia Civil) — COPPE, Universidade Federal do Rio de Janeiro, Rio de Janeiro, 2001.

CHIU, S. Fuzzy model identification based on cluster estimation. **Journal of Intelligent & Fuzzy Systems**, Amsterdam, v.2, n.3, Sept. 1994.

COHEN, W. B. ; SPIES, T. A. ; FIORELLA, M. Estimating the age and structure of forests in a multi-ownership landscape of western Oregon, USA. **International Journal of Remote Sensing**, London, v.16, n. 4, p. 721-746. Mar. 1995.

COUPINOT, G. et al. Photometric analysis of astronomical images by the wavelet transform. **Astronomy and Astrophysics**, Les Ulis, v. 259, n.2, p.701–710, 1992.

CRIST, E. P. ; CICONE, R. C. Application of the tasseled cap concept to simulated thematic mapper data (transformation for MSS crop and soil imagery). **Photogrammetric Engineering and Remote Sensing**, Fall Church, v.50, n. 3, p.343-352, 1984.

CRUZ, A. J. D. O. **Lógica nebulosa**: Rio de Janeiro: Universidade Federal do Rio de Janeiro, 2004 .Apostila

CRUZ, A. J. D. O. **Lógica nebulosa**. 2007. Disponível em:
<<http://equipe.nce.ufri.br/adriano/fuzzy/ln.htm>>. Acesso em: 2008.

DAUBECHIES, I. **Ten lectures on wavelets**. Philadelphia: SIAM, 1992.

DEMUTH, H. ; BEALE, M. **Neural network toolbox for use with MATLA**. Natick: MathWorks, 1998.

DOMINGUES, M. O. ; MENDES JR., O. M. ; COSTA, A. M. D. Algumas aplicações wavelet na análise de sinais atmosféricos. CONGRESSO TEMÁTICO DE APLICAÇÕES DE DINÂMICA E CONTROLE DA SOCIEDADE BRASILEIRA DE MATEMÁTICA APLICADA E COMPUTACIONAL, 2., 2003, São José dos Campos. **Anais ...** São José dos Campos, 2003. p. 18-22. Slides.

DRIANKOV, D. ; HELLENDORRN, H. ; REINFRANK, M. **An introduction to fuzzy control**. Berlin: Springer-Verlag, 1993.

DUDA, R. O. ; HART, P. E. **Pattern classification and scene analysis**. New York: John Wiley, 1973.

EMBRAPA. 2008. Disponível em: <<http://www.embrapa.br/>>. Acesso em: 2008.

EOS. Measuring vegetation (NDVI & EVI). 2008. Disponível em: <<http://earthobservatory.nasa.gov/Features/MeasuringVegetation/>>. Acesso em: 2008.

EASTMAN, J. R. **Guide to GIS and image processing**. Worcester: Clark Labs, v.2, 2001.

EPINATL, V. et al. A wavelet characterization of high-resolution NDVI patterns for precision agriculture. **International Journal of Applied Earth Observation and Geoinformation**, Amsterdam, v. 3, n. 2, p. 121-132, 2001.

ESTER, M. ; KRIEGEL, H.-P. ; XU, X. A Database Interface for clustering in large spatial databases. In: INTERNATIONAL CONFERENCE ON KNOWLEDGE DISCOVERY IN DATABASES AND DATA, 1., 1995, Montreal. **Proceedings ...** Montreal, 1995. p. 94-99 .

FULLÉR, R. **Neural Fuzzy Systems**. Turku: Åbo Akademis 1995

GLERIANI, J. M. ; EPIPHANIO, J. C. N. ; SILVA, J. D. S. D. Classificação espectro-temporal de culturas agrícolas tropicais: tolerância de dois modelos de redes neurais a dados falhos. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO. 2005, Goiânia. **Anais ...** Goiania: INPE, 2005. 151-158 p.

GOUPILLAUD, P. ; GROSSMANN, A. ; MORLET, J. Cycle-octave and related transforms in seismic signal analysis. **Geoexploration**, Amsterdam, v.23, p. 85–102. 1985.

GROSSBERG, S. **Classical and instrumental learning by neural networks. progress in theoretical biology**. New York: Academic Press, 1974. v. 3.

GUERRA, R. **Projeto e simulação do controle de atitude autônomo de satélites usando lógica nebulosa**. São José dos Campos: Instituto Nacional de Pesquisas Espaciais - INPE, 1998.

HARTIGAN, J. A. ; WONG, M. A. Algorithm AS 136: a k-means clustering algorithm. **Journal of The Royal Statistical Society. Series C. Applied Statistics**, v.28, n. 1, p.100-108. 1979.

HAYKIN, S. E. **Redes neurais: princípios e prática**. Porto Alegre: Bookman, 2001.

HORGAN, G. Wavelets for SAR image smoothing. **Photogrammetric Engineering and Remote Sensing**, Fall Church, v. 64, n. 12, p. 1171-1177, 1998.

HUETE, A. R. A soil-adjusted vegetation index (SAVI). **Remote Sensing and the Environment**, Amsterdam, v. 25, n. 3, p. 295-302, Aug. 1988.

ÍBEYLI, D. E. Adaptive neuro-fuzzy inference system employing wavelet coefficients for detection of ophthalmic arterial disorders. **Expert Systems with Applications: An International Journal**, Tarrytown, v.34, n.3, p. 2201-2209, Apr. 2008.

JACKSON, R. D. Spectral Indices in n-space. **Remote Sensing and the Environment**, Amsterdam, v. 13, n. 5, p. 391-402, Nov. 1983.

JANG, J.-S. R. ANFIS: adaptive-network-based fuzzy inference systems,. **IEEE Transactions on Systems, Man, and Cybernetics**, Piscataway, v.23, n. 3, May/Jun. 1993. .

JONATHAN, M. **Classificação do uso e cobertura do solo em escala regional a partir de seqüências temporais de dados modis**. 2005. 142 f. Dissertação(Mestrado em Geomática) — Faculdade de Engenharia, Universidade do Estado do Rio de Janeiro, Rio de Janeiro, 2005.

JONATHAN, M. et al. Considerações para o monitoramento do uso do solo com dados modis para longos períodos e em escala regional, e sua aplicação na Bacia do Alto Taquari, MS/MT. **RBC. Revista Brasileira de Cartografia**. Rio de Janeiro, n. 59/1, p. 1 - 7, abr. 2007.

JUSTICE, C. O. et al. Analysis of the phenology of global vegetation using meteorological satellite data. **International Journal of Remote Sensing**, London, v.6, n. 8, p.1271-1318, Aug. 1985.

KAUFMAN, L. ; ROUSSEUW, P. J. **Finding groups in data**: an introduction to cluster analysis. New York: John Wiley, 1990

KAUTH, R. J. ; THOMAS, G. S. The tasseled cap -- a graphic description of the spectral-temporal development of agricultural crops as seen by LANDSAT. In: SYMPOSIUM ON MACHINE PROCESSING OF REMOTELY SENSED DATA, 1976, West Lafayette. **Proceedings ...** Purdue University of West Lafayette, Indiana: IEEE, 1976. p. 4B-41- 4B-51.

KLIR, G. J. ; FOLGER, T. A. **Fuzzy sets, uncertainty, and Informations**. London: Prentice Hall, 1988.

KOHONEN, T. Clustering, taxonomy, and topological maps of patterns. In: INTERNATIONAL CONFERENCE ON PATTERN RECOGNITION, 6., 1982, Munich. **Proceedings ...** Minich: IEEE, 1982. p. 114-128.

KOHONEN, T. **Self-organizing maps**. Berlin: Springer, 2001

KOVÁCS, Z. L. **O Cérebro e a sua mente**: uma introdução à neurociência computacional. São Paulo: Edição Acadêmica, 1997.

LEE, C. C. Fuzzy logic in control systems: fuzzy logic controller (part i). **IEEE Transactions on Systems, Man and Cybernetics**, Piscataway, v. 20, n. 2, p. 404 – 418, Mar./Apr. 1990.p.

LIN, C.-T.; LEE, C.-C. **Neural fuzzy systems**. a neuro-fuzzy synergism to intelligent systems. New York: Prentice Hall, 1996.

LUCCA, E. V. D. **O uso da fusão de imagens multisensores por meio da transformada wavelet na caracterização da pluma termal costeira da usina nuclear de Angra dos Reis**. 2006 Tese (Doutorado em Sensoriamento Remoto) -- Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 2006.

MAFRA, E. L. **Processamento de Imagens Digitais: Uma abordagem utilizando conjunto difusos**. 1994 Dissertação(Doutorado em Engenharia de Produção) — Universidade Federal de Santa Catarina, Florianópolis, 1994.

- MALLAT, S. A. Theory for multiresolution signal decomposition: the wavelet representation. **IEEE Transactions on Pattern Analysis and Machine Intelligence**, Piscataway, v.11, n.7, p. 674-693, Jul. 1989.
- MAMDANI, E. H. A. S. A. An experiment in linguistic synthesis with a fuzzy logic controller. **International Journal of Man-Machine Studies**, v.7, n. 1, p. 1-13, 1975.
- MANN, S. **Intelligent image processing**. New York: John Wiley, 2003.
- MAS, J.-F. Classificação de imagens utilizando dados auxiliares numa abordagem nebulosa. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 8., 1996, Salvador. **Anais ...** Salvador: INPE, 1996. p. 713-716.
- MATHER, P. M. **Computer processing of remotely-sensed images: an introduction**. New York: John Wiley, 2004.
- MATHWORKS, T. **MATLAB** - the language of technical computing.(2006). Disponível em: <<http://www.mathworks.com/products/matlab/>>. Acesso em: 2007.
- MEIRELLES, M. S. P. et al. Subsídios da geomática para avaliação da influência da dinâmica do uso do solo nos serviços ecossistêmicos In: BRANQUINHO, F. ; FELZENSWALB, I. **Meio ambiente: experiências em pesquisa multidisciplinar e formação de pesquisadores**. Rio de Janeiro: MAUAD, 2007.
- MISITI, M. et al. **Wavelet toolbox user's guide**. Natick: The MathWorks, 2002.
- NASA. **Moderate resolution imaging spectroradiometer**. 2007. Disponível em: <<http://modis.gsfc.nasa.gov>> Acesso em: 2007.
- NAUCK, D. ; KLAWONN, F. ; KRUSE, R. **Foundations of neuro-fuzzy systems**. New York: John Wiley, 1997.
- NOGUCHI, M. T. G. **Um sistema baseado em regras fuzzy para classificação supervisionada de imagens multiespectrais de alta resolução** 2004. Dissertação (Mestrado em Informática) — Universidade Federal do Paraná, Curitiba, 2004.
- PICOLI, M. C. A. **Estimativa da produtividade agrícola da cana-de-açúcar utilizando agregados de redes neurais artificiais: estudo de caso, Usina Catanduva**. 2007. Dissertação (Mestrado em Sensoriamento remoto) — Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 2007.

RIBEIRO, L. N. **Rede neural com retropropagação**: uma aplicação na classificação de imagens de satélite. 2003 Dissertação (Mestrado em Ciência da Computação) — Departamento de Computação e Estatística, Universidade Federal de Mato Grosso do Sul, Campo Grande, 2003.

RIBEIRO, S. R. A. ; CENTENO, J. S. Classificação do uso do solo utilizando redes neurais e o algoritmo MAXVER. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 10., 2001, Foz do Iguaçu. **Anais ...** Foz do Iguaçu: INPE, 2001. p. 1341-1348.

RICHARDSON, A. J. ; WIEGAND, C. L. Distinguishing vegetation from soil background information. **Photogrammetric Engineering and Remote Sensing**, Fall Church, v. 43, n. 2, p. 1541-1552, 1977.

ROUSE, J. W. J. et al. Monitoring vegetation systems in the great plains with ERTS. In: EARTH RESOURCES TECHNOLOGY SATELLITE - 1 SYMPOSIUM, 3., .1973, Washington. **Proceedings ...** Washington: NASA, 1973. p. 309-317.

SANDRI, S. ; CORREA, C. **Lógica nebulosa**. São José dos Campos: INPE 1999.

SCHALKOFF, R. J. **Pattern recognition, statistical, structural and neural approaches**. New York, John Wiley, 1992.

SENGUR, A. Wavelet transform and adaptive neuro-fuzzy inference system for color texture classification. **Expert Systems with Applications: An International Journal**, New York, _v. 34, n.3, p. 2120-2128, Apr. 2008.

STARCK, J.-L. ; MURTAGH, F. ; BIJAOU, A. **Image processing and data analysis: the multiscale approach**. Cambridge: Cambridge University Press, 1998.

STRANG, G. ; NGUYEN, T. **Wavelets and filter banks**. Wellesley: Wellesley-Cambridge Press, 1996.

SUGENO, M. **Industrial applications of fuzzy control**. New York: Elsevier Science, 1985.

SYNAPTIC. **Fuzzy math**. Part 1, The Theory (2006). Disponível em: <<http://blog.peltarion.com/2006/10/25/fuzzy-math-part-1-the-theory/>>. Acesso em: 2008.

USGS. LP DAAC. **Data pool** . aster and modis land data products and services. (2006). Disponível em: <https://lpdaac.usgs.gov/lpdaac/get_data/data_pool>. Acesso em: 2007.

VON DER MALSBURG, C. Self-organization of orientation sensitive cells in the striate cortex. **Kybernetik**, Berlin, v.14, n. 2, p.85-100. 1973.

WALKER, J. S. **Fourier analysis**. New York: Oxford University Press, 1988.

XIN, J. Y. Z. ; VAN LEEUWEN, L. ; DRIESSEN, P. M. Mapping crop key phenological stages in the North China plain using NOAA time series images. **International Journal of Applied Earth Observation and Geoinformation**, Enschede, v.4, n.2, p.109-117. 2002.

YAGER, R. ; FILEV, D. Generation of fuzzy rules by mountain clustering,. **Journal of Intelligent & Fuzzy Systems**, Amsterdam, v.2, n.3, p.209-219. 1994.

YOCKY, D. A. Multiresolution wavelet decomposition image merger of LANDSAT thematic mapper and SPOT panchromatic data. **Photogrammetric Engineering and Remote Sensing**, Fall Church, v. 62, n. 9, p.1067-1074. 1996.

ZADEH, L. A. Fuzzy sets. fuzzy sets, **Information and Control**, New York, v.8, n. 3, p. 338 – 353, 1965.

ZHOU, J.; CIVCO, D. L.; SILANDER, J. A. A wavelet transform method to merge Landsat TM and SPOT panchromatic data. **International Journal of Remote Sensing**, London, v. 19, n. 4, p.743-757, 1998.

ZHU, C. ; YANG, X. Study of remote sensing image texture analysis and classification using wavelet. **International Journal of Remote Sensing of Environment**, London, v. 19, n. 16, p.3197-3203. 1998.

ZIMMERMANN, H.-J. **Fuzzy set theory and its applications**. 4. ed. Norwell: Kluwer, 2001

