

DESENVOLVIMENTO DE UM SISTEMA DE SUPORTE A
DECISÃO PARA MONITORAMENTO DO USO E OCUPAÇÃO DO
SOLO UTILIZANDO DADOS DE SENSORIAMENTO REMOTO

SUSANA BRUNORO COSTA DE OLIVEIRA

UNIVERSIDADE ESTADUAL DO NORTE FLUMINENSE
DARCY RIBEIRO

CAMPOS DOS GOYTACAZES – RJ
OUTUBRO - 2012

DESENVOLVIMENTO DE UM SISTEMA DE SUPORTE A
DECISÃO PARA MONITORAMENTO DO USO E OCUPAÇÃO DO
SOLO UTILIZANDO DADOS DE SENSORIAMENTO REMOTO

SUSANA BRUNORO COSTA DE OLIVEIRA

“Tese apresentada ao Centro de Ciências e
Tecnologias Agropecuárias da Universidade
Estadual do Norte Fluminense Darcy Ribeiro,
como parte das exigências para obtenção do
título de Doutor em Produção Vegetal.”

Orientador: Geraldo de Amaral Gravina

CAMPOS DOS GOYTACAZES – RJ
OUTUBRO - 2012

FICHA CATALOGRÁFICA

Preparada pela Biblioteca do CCTA / UENF 085/2012

Oliveira, Susana Brunoro Costa de

Desenvolvimento de um sistema de suporte a decisão para monitoramento do uso e ocupação do solo utilizando dados de sensoriamento remoto / Susana Brunoro Costa de Oliveira. – 2012.

59 f. : il.

Orientador: Geraldo de Amaral Gravina

Tese (Doutorado - Produção Vegetal) – Universidade Estadual do Norte Fluminense Darcy Ribeiro, Centro de Ciências e Tecnologias Agropecuárias. Campos dos Goytacazes, RJ, 2012.

Bibliografia: f. 55 – 59.

1. Redes neurais artificiais 2. Índice de vegetação 3. Sistema DOS 4. Sistema de Informação Geográfica I. Universidade Estadual do Norte Fluminense Darcy Ribeiro. Centro de Ciências e Tecnologias Agropecuárias. II. Título.

CDD –
631.4

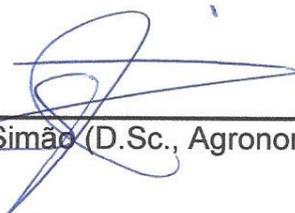
DESENVOLVIMENTO DE UM SISTEMA DE SUPORTE A
DECISÃO PARA MONITORAMENTO DO USO E OCUPAÇÃO DO
SOLO UTILIZANDO DADOS DE SENSORIAMENTO REMOTO

SUSANA BRUNORO COSTA DE OLIVEIRA

“Tese apresentada ao Centro de Ciências e Tecnologias Agropecuárias da Universidade Estadual do Norte Fluminense Darcy Ribeiro, como parte das exigências para obtenção do título de Doutor em Produção Vegetal.”

Aprovada em 11 de outubro de 2012

Comissão Examinadora



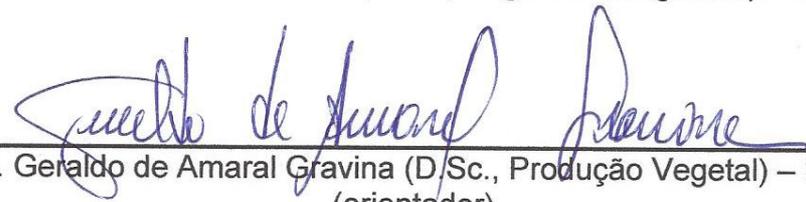
Prof. João Batista Pavesi Simão (D.Sc., Agronomia) – IFES Campus de Alegre



Profª. Annabell Del Real Tamariz (D.Sc., Engenharia Eletrica) – UENF



Prof. Ricardo Ferreira Garcia (D.Sc., Engenharia Agrícola) – UENF



Prof. Geraldo de Amaral Gravina (D.Sc., Produção Vegetal) – UENF
(orientador)

A Deus, meu refúgio e minha fortaleza;
Ao meu esposo Janio, meu amor e sustentáculo;
Aos meus filhos Lucas e Ana Luiza, meus amores em plenitude;
À minha mãe, meu exemplo de vida;
À memória do meu pai e do meu irmão Carlos Ney.

AGRADECIMENTO

A Deus, acima de tudo, por todas as bênçãos derramadas.

Ao meu esposo Janio, por sua cumplicidade, compreensão e incentivo em cada momento.

Aos meus filhos, pelo carinho, pela compreensão em minha ausência e por tudo que aprendo com eles.

Ao professor Gravina, grande orientador e amigo, por seus ensinamentos que foram tão ricos para mim e por seu exemplo como profissional que, certamente, guardarei para sempre.

A todos os professores do programa de pós-graduação em Produção Vegetal da UENF, por seus ensinamentos.

À professora Annabell Del Real Tamariz por sua amizade e seus ensinamentos.

Aos amigos de turma de doutorado, pelo companheirismo e troca de conhecimento.

A todos os meus familiares pelo apoio e incentivo.

Ao Ifes – Campus de Alegre, CAPES e UENF pelo apoio.

SUMÁRIO

1. INTRODUÇÃO.....	1
2. REVISÃO DA LITERATURA.....	3
2.1. Sensoriamento Remoto	3
2.1.1. O Processo de Formação das Imagens e das Cores.....	5
2.1.2. O Programa Espacial Landsat	10
2.2. Correção Atmosférica	12
2.2.1. Cálculo de Reflectância.....	13
2.3. Índice de Vegetação	14
2.3.1. Índice de Vegetação por Diferença Normalizada (NDVI)	15
2.3.2. Índice de Realce de Vegetação (EVI)	17
2.4. Softwares de Informações Geográficas Existentes no Mercado.....	18
2.4.1. SPRING	18
2.4.2. ARCGIS	19
2.4.3. EASI/PACE	19
2.4.4. ERDAS IMAGINE.....	20
2.4.5. ENVI EX.....	20
2.4.6. IDRISI Taiga.....	21
2.4.7. CLASLITE	21
2.5. Sistemas de Suporte a Decisão.....	22
2.6. Redes Neurais Artificiais.....	23
2.6.1. Introdução	23
2.6.2. Tipo de Redes Neurais Artificiais	26

2.6.3.	Processo de Execução das Redes Neurais	27
2.6.4.	Redes Neurais para Processamento de Imagens	28
2.6.5.	Avaliação da Precisão da Classificação dos Dados.....	29
2.6.6.	Matriz de Confusão	29
2.6.7.	Coeficiente Kappa	30
3.	MATERIAL E MÉTODOS	32
3.1.	Características Funcionais do Software.....	32
3.2.	Correção Atmosférica	33
3.3.	Área de Estudo	38
3.4.	Algoritmo de Classificação.....	39
3.5.	Arquitetura da Rede Neural Artificial Utilizada	39
3.6.	Geração da Imagem Classificada.....	41
4.	RESULTADOS E DISCUSSÕES.....	43
4.1.	Correção Atmosférica	43
4.2.	Rede Neural Artificial	48
5.	CONCLUSÃO	53
	REFERÊNCIAS BIBLIOGRÁFICAS	55

LISTA DE FIGURAS

Figura 1 - Espectro Eletromagnético (Hashimoto, 2003).....	4
Figura 2 - curva de reflectância espectral típica para solo exposto, vegetação e água (adaptada de Fas, 2010).	5
Figura 3 - Imagem da cidade de Cachoeiro de Itapemirim, ES obtida pelo satélite Landsat nas composições 3-4-5 e 5-4-3 respectivamente.....	6
Figura 4 - Imagem do satélite Landsat 5 do sul do Espírito Santo com a identificação dos pontos que correspondem a (a) Mata Atlântica, (b) oceano, (c) nuvens, (d) área urbana, (e) Pico da Bandeira.....	8
Figura 5 - Ilustração do NDVI calculado para uma região de vegetação saudável (esquerda) e outra de vegetação escassa (direita) (adaptada de Weier e Herring, 2010).	17
Figura 6 - Os estágios da tomada de decisão e seu relacionamento com a solução do problema (adaptada de Simon, 1965).....	23
Figura 7 - Esquema da constituinte de uma célula neural (Carvalho, 2009). ...	24
Figura 8 - Modelo de neurônio artificial proposto por McCulloch e Pitts (Tatibana e Kaetsu, 2010).	25
Figura 9 - Diagrama de atividades das etapas de correção atmosférica das imagens.....	34
Figura 10 - Diagrama de atividades das etapas que compõem o processo de cálculo da reflectância.....	37
Figura 11 - Composição RGB da imagem do sensor TM que compreende o município de Cachoeiro de Itapemirim.	41
Figura 12 - Gráfico de uso e ocupação do solo.....	42
Figura 13 - Parâmetros da imagem informados ao sistema para cálculo da reflectância.....	43

Figura 14 - Recorte do Histograma de Frequência da Banda 1 da imagem de 23/05/2007.	44
Figura 15 - Parâmetros dos sensores TM e ETM+.	45
Figura 16 - Comprimento de onda médio de cada banda da imagem.....	46
Figura 17 - Espalhamento + <i>offset</i>	46
Figura 18 - parâmetro do sensor correspondente à irradiância da banda.....	47
Figura 19 - Tabela i, j e multi com parâmetros para o cálculo de reflectância..	47
Figura 20 - Recorte da tabela de valores de reflectância calculados.	48
Figura 21 - Esquema da arquitetura da RNA utilizada com 7 neurônios na camada de entrada, 6 na camada intermediária e 5 na camada de saída.....	48
Figura 22 - Parâmetros de configuração da RNA.....	49
Figura 23 - Recorde do arquivo de conhecimento com pesos sinápticos de cada conexão entre os neurônios da RNA.....	49
Figura 24 - Matriz de Confusão e Índice Kappa resultante do teste da rede neural.	50
Figura 25 - Classificação da imagem pelo software Ative.	51
Figura 26 - Classificação da imagem ano a ano	51
Figura 27 - Tela de saída do sistema Ative com a tabela do total de pontos classificados e o gráfico de uso e ocupação do solo.....	52

RESUMO

OLIVEIRA, Susana Brunoro Costa de; D.Sc.; Universidade Estadual do Norte Fluminense Darcy Ribeiro; outubro de 2012; Desenvolvimento de um Sistema de Suporte a Decisão para Monitoramento do Uso e Ocupação do Solo Utilizando Dados de Sensoriamento Remoto. Orientador: Prof. Geraldo de Amaral Gravina, D.Sc.

O desmatamento desordenado, tanto para urbanização, quanto para a agricultura e pecuária, tem desencadeado um processo de degradação do meio natural, tornando escassa a presença de vegetação nativa e de mananciais. Assim, faz-se necessário medir e monitorar o processo de ocupação da terra, para a elaboração de um planejamento adequado pelos órgãos competentes, sempre visando o melhoramento da qualidade de vida e a harmonia do ecossistema. O presente trabalho apresenta os resultados obtidos com o desenvolvimento de um sistema de suporte a decisão que analisa imagens dos sensores Landsat TM e ETM+ de uma mesma região em períodos distintos configuráveis para gerar informações que servirão de base para analisar o uso e ocupação do solo no local ao longo do tempo. Inicialmente, são apresentados os processos de cálculo de reflectância das imagens captadas por meio do método de subtração do objeto escuro (DOS) e do cálculo de índice de vegetação por diferença normalizada (NDVI), que tem como dados de entrada o histograma de frequência dos números digitais da imagem e características dos equipamentos sensores, da atmosfera na data da obtenção da imagem. Em seguida, é apresentado o processo de classificação por meio de um modelo de rede neural artificial (RNA) que tem, como dados de entrada, as imagens provenientes do satélite. A ocupação do solo é classificada em cinco grandes grupos: áreas urbanas, fragmentos de florestas,

culturas, solo exposto e água. A arquitetura utilizada é a *Perceptron* Multicamada (MLP) com *backpropagation* com sete neurônios na camada de entrada, cinco na camada de saída e uma camada intermediária com seis neurônios. A avaliação dos resultados é realizada pelo índice *Kappa*, no qual, obteve desempenho de 85,8%. A classificação que apresentou maior erro foi da área de culturas e o melhor desempenho foi apresentado na classificação das imagens de água, atingindo 100%. O resultado é apresentado por meio de imagens bitmap, tabela e gráfico. A solução desenvolvida se mostrou adequada para o problema proposto.

Palavras-chave: Redes neurais artificiais, Índice de vegetação, Sistema DOS, Sistema de Informação Geográfica.

ABSTRACT

OLIVEIRA, Susana Brunoro Costa de; D.Sc.; Universidade Estadual do Norte Fluminense Darcy Ribeiro; October - 2012; Development of a Decision Support System for Monitoring of Land's Usage and Occupation Using Remote Sensing Data. Adviser: Prof. Geraldo de Amaral Gravina, D.Sc.

The uncontrolled deforestation for urbanization, whether for agriculture and cattle rising, has triggered a process of degradation of the natural environment, becoming scarce the presence of native vegetation and water sources. Thus, it is necessary to measure and monitor the process of land occupation, for the development of adequate planning by the competent organizations, always aiming the life quality improvement and the harmony of the ecosystem. This study presents the result of the development of a decision support system which analyzes images from Landsat TM and ETM+ sensors from only one region in different periods to generate information about the vegetation index and soil usage and occupation over time. First of all, the reflectance calculation of the captured images' process by DOS method and the vegetation index NDVI are presented. Then, the classification process by an artificial neural network with the satellite's images as input is presented. The soil's usage and occupation is classified into five groups: urban, forest fragments, crops, bare soil and water. The architecture used to perform the classification is the multilayer perceptron with backpropagation with 7 neurons at input layer, 5 at output layer and 6 at intermediate layer. The result's evaluation is performed by Kappa index with reached 85,8% performance. The

classification that presented the biggest error was the crops area and the best performance was the water areas, reaching 100%. The result is presented by bitmap images, tables and chart. The developed solution was adequate for the proposed problem.

Keywords: Artificial neural network, vegetation index, DOS System, Geographic information system.

1. INTRODUÇÃO

Desde o período colonial, o uso e a ocupação das terras brasileiras se dão por meio de exploração desordenada dos seus recursos naturais. A cultura exploratória dos colonizadores, aliada às práticas rudimentares e itinerantes de cultivo, implantou marcas profundas em nossas paisagens. Somente no século XX, teve início a transição de um modelo de exploração de recursos para um modelo de conservação, entretanto, perduram até os dias atuais a exploração indiscriminada e a má utilização dos recursos naturais.

A compreensão da importância da conservação dos recursos naturais é recente. Depois de séculos de exploração desordenada, o homem tem percebido empírica e cientificamente que precisa preservar os recursos renováveis e controlar a exploração dos recursos não renováveis para garantir a qualidade de vida das gerações futuras dentro de parâmetros aceitáveis. Dessa forma, é de fundamental importância que haja instrumentos eficientes de monitoramento da ocupação e utilização da terra pelo homem.

O sensoriamento remoto orbital tem se mostrado um forte aliado nesse monitoramento. Imagens digitais extraídas de sensores remotos a bordo de satélites têm sido usadas para se fazer medições da superfície da Terra e transmitir dados espectrais para uma rede global de estações receptoras estrategicamente localizadas. Dados desses satélites de observação terrestre são usados para mapear, monitorar e gerenciar os recursos naturais e culturais

da terra (Morain, 1998). A manipulação das imagens digitais orbitais dos satélites normalmente é feita por um segmento de softwares específicos denominados sistemas de processamento de imagens, no qual se tem investido grandes recursos técnicos e humanos e, por isso, a evolução desse segmento tem respondido de modo eficiente às demandas do sensoriamento remoto (Figueiredo, 2005).

O processamento de imagens, aliado a um sistema de suporte a decisão, possibilita a visualização mais precisa dos dados e a percepção de transformações difíceis de serem humanamente observadas. Por isso, o presente trabalho visa apresentar os resultados obtidos com o desenvolvimento de uma ferramenta para monitorar o uso e a ocupação do solo e assim contribuir para o desenvolvimento sustentável e a preservação dos recursos naturais. O software desenvolvido utiliza ferramentas de geotecnologia, sensoriamento remoto e sistemas inteligentes, como imagens de satélite, sistemas de informações geográficas e serviço de consulta. Os mapas e as imagens georreferenciadas da região são fornecidos, gratuitamente, pela *web*, para que os empreendedores elaborem seus projetos de forma mais eficiente e segura, garantindo a sustentabilidade ambiental. Pretende-se que o resultado desse trabalho seja uma ferramenta de apoio para pesquisadores, órgãos governamentais e não governamentais (ONGs) e instituições acadêmicas, para que possam mapear e monitorar as paisagens utilizando imagens obtidas de satélite.

Para a avaliação do desempenho do sistema em um estudo de caso, foi escolhida a imagem da região da carta topográfica de Cachoeiro de Itapemirim, no sul do estado do Espírito Santo, Brasil, que se caracteriza por possuir uma economia que se baseia na exploração de rochas ornamentais, em especial o mármore e o granito, e na atividade agropecuária, ambas responsáveis pela exaustão das riquezas naturais e merecedoras de um acompanhamento mais preciso e rico em informações. Segundo a Fundação SOS Mata Atlântica (Atlântica, 2009), o município de Cachoeiro de Itapemirim possui atualmente apenas 10% de vegetação original.

2. REVISÃO DA LITERATURA

2.1. Sensoriamento Remoto

A busca contínua de conhecimento sobre o planeta levou o homem à necessidade de desenvolver novas tecnologias para mapeá-lo. Um setor que muito tem contribuído com essa tarefa, nos últimos tempos, é o de obtenção de imagens captadas por sensores remotos instalados em satélites artificiais na órbita terrestre. A essa técnica, dá-se o nome de sensoriamento remoto (SR).

O sensoriamento remoto é viabilizado pela reflexão da radiação eletromagnética sobre os objetos estudados. Em seguida é realizada a coleta de dados e seu registro por meio de um sensor e a análise desses dados com o objetivo de extrair as informações pretendidas de um dado objeto (Ponzoni, 2002).

A energia eletromagnética, quando atravessa a atmosfera terrestre, pode ser absorvida, refletida e transmitida total ou parcialmente, essas capacidades são denominadas respectivamente de absortância, reflectância e transmitância e são medidas por valores no intervalo entre 0 e 1. Os valores da reflectância de um objeto ao longo do espectro eletromagnético definem a sua assinatura espectral, que por sua vez, define as suas feições. Essas feições são captadas pelos sensores remotos dos satélites, que transformam a energia eletromagnética do alvo em sinal elétrico. Esse sinal é quantificado e forma uma matriz de números digitais (ND) que, nos sensores TM dos satélites Landsat 5 e 7, podem assumir 256 valores diferentes, entre 0 e 255. Cada valor diferente corresponde a uma intensidade diferente do tom de cinza e juntos possibilitam analisar os alvos

estudados. Entretanto, quando se pretende comparar imagens oriundas de sensores ou épocas diferentes, faz-se necessário que se utilizem os valores de reflectância dos alvos presentes na cena.

Segundo Florenzano (2002), a energia usada em sensoriamento remoto é a radiação eletromagnética (REM), que se propaga em forma de ondas eletromagnéticas com a velocidade da luz (300.000 km/s). Ela é medida em frequência (Hz) e comprimento de onda. A frequência de onda é o número de vezes que uma onda se repete por unidade de tempo. A faixa de comprimento de onda e de frequência da REM é denominada espectro eletromagnético e está ilustrado na Figura 1.

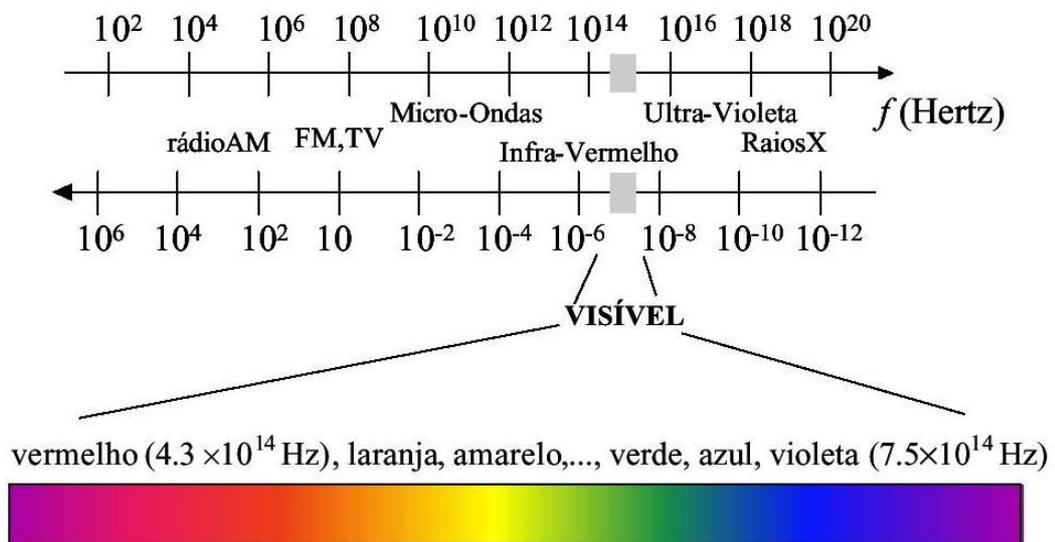


Figura 1 - Espectro Eletromagnético (Hashimoto, 2003).

O espectro eletromagnético representa a distribuição da radiação eletromagnética por regiões, de acordo com o comprimento e a frequência da onda. A região do visível é aquela na qual o olho humano é capaz de enxergar a energia eletromagnética refletida e transmitida por objetos terrestres. A vegetação, a água e o solo são exemplos de objetos terrestres, que podem refletir, absorver ou transmitir radiação eletromagnética, de acordo com suas características bio-físico-químicas, conforme pode ser observado na Figura 2.

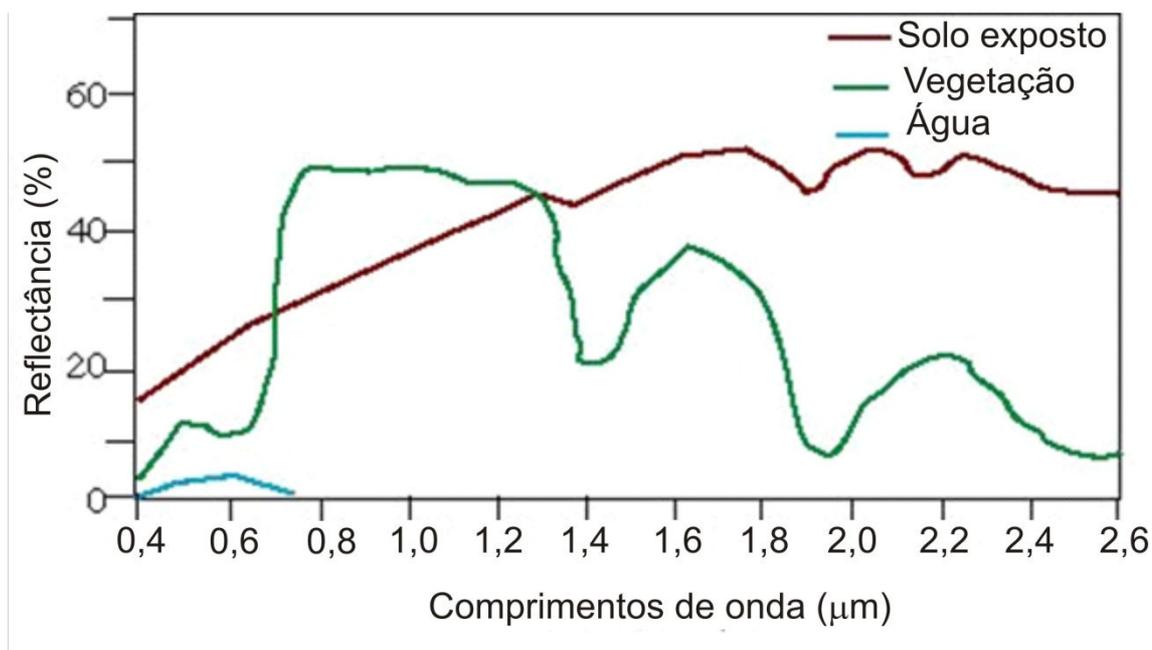


Figura 2 - curva de reflectância espectral típica para solo exposto, vegetação e água (adaptada de Fas, 2010).

2.1.1. O Processo de Formação das Imagens e das Cores

O olho humano é um sensor natural que enxerga somente a luz ou energia visível. O sensor eletrônico multiespectral TM, do satélite Landsat-5, por exemplo, é um sistema de varredura que capta dados em diferentes faixas espectrais (três regiões do visível e quatro do infravermelho).

A resolução de um sensor refere-se à sua capacidade de distinguir objetos da superfície terrestre. Mais especificamente, a resolução espacial pode ser definida como o menor elemento ou superfície distinguível de um sensor. Desta forma, um sensor ETM⁺, do satélite Landsat-7, cuja resolução espacial é de 30 m, tem a capacidade de distinguir objetos que medem, no terreno, 30 m ou mais. Isso equivale dizer que 30 m x 30 m (900 m²) é a menor área que o sensor ETM⁺ consegue enxergar.

O comportamento ou assinatura espectral de um objeto está relacionado ao seu processo de interação com a radiação eletromagnética incidente. Esse processo depende da estrutura atômica e molecular de cada alvo. Os elétrons dos materiais estão distribuídos em diferentes níveis energéticos, em torno dos núcleos de seus átomos. Estes níveis eletrônicos podem absorver maior ou menor quantidade da energia da REM. Esta absorção implica na diminuição da

quantidade de energia da REM refletida pela matéria, em certas faixas do espectro eletromagnético, faixas estas denominadas bandas de absorção (Figueiredo, 2005).

As cores dos objetos são formadas pela atribuição das cores primárias RGB (*red, green and blue*: vermelho, verde e azul, respectivamente) a três bandas espectrais quaisquer. A Figura 3 mostra o município de Cachoeiro de Itapemirim, ES, em duas composições distintas: na figura 6-a, as cores vermelha, verde e azul estão associadas respectivamente às bandas 3, 4 e 5 e na figura 6-b, as mesmas cores estão associadas às bandas 5, 4 e 3 respectivamente. Como pode ser observado, embora a figura 6-b apresente um resultado mais real, nos dois casos é possível distinguir, com igual nitidez, os componentes da paisagem.

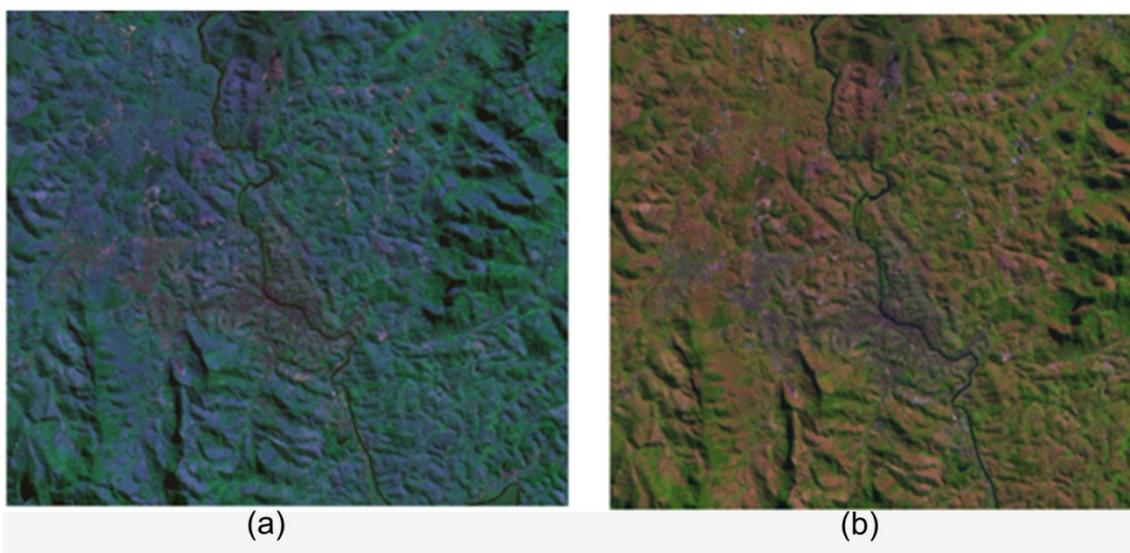


Figura 3 - Imagem da cidade de Cachoeiro de Itapemirim, ES obtida pelo satélite Landsat nas composições 3-4-5 e 5-4-3 respectivamente.

As imagens de SR são formadas por pontos, linhas e polígonos que demandam interpretação visual para a geração das informações necessárias. Essa interpretação baseia-se em algumas características, tais como cor, textura, tamanho, forma, sombra e padrão.

A cor, também denominada tom, de um dado pixel, refere-se à tonalidade de cinza, brilho relativo ou cor do objeto/alvo mostrado na imagem. Em uma única banda ou canal, todos os pixels são representados em tons de cinza e para que se crie uma imagem colorida, é necessário que se associe uma banda a uma das cores primárias RGB, como apresentado anteriormente na Figura 3. Quanto maior a radiação refletida de um objeto, mais claro será o seu tom e aqueles que absorvem muita energia, ao contrário, aparecerão mais escuros.

As formas estão relacionadas com as feições dos alvos e são uns dos fatores mais importantes na identificação dos objetos. De um modo geral, os objetos naturais, como matas e rios, têm formas irregulares, enquanto que os elementos antrópicos como plantações, construções e lagos artificiais tendem a ter formas mais regulares.

O tamanho do objeto ou alvo visto na imagem está relacionado com as dimensões de sua superfície, mas deve ser interpretado de forma relativa, com base no contexto da imagem. É pelo tamanho, que se distingue, por exemplo, uma área de preservação ambiental de um segmento de floresta ou uma área residencial de uma industrial em uma cidade.

O padrão diz respeito ao arranjo espacial das feições visíveis na imagem. Uma linha escura atravessando a imagem, por exemplo, deixa clara a presença de um rio.

A textura vem a ser o arranjo dos objetos e a frequência da sua variação de tons que se verifica em certas áreas da imagem. Quando essas variações são pequenas, tem-se uma textura lisa, como nos gramados, por exemplo, e quando as variações são abruptas, tem-se a textura dita rugosa, como acontece com a copa das árvores.

A sombra de um objeto na imagem dá uma ideia do seu perfil e altura, facilitando o seu reconhecimento. É um elemento útil para realçar ou identificar as feições topográficas e as formas do relevo. Assim, a partir da sombra, outros elementos, como a forma e o tamanho, podem ser inferidos. Entretanto, se por um lado a sombra ajuda a identificar os elementos, por outro, pode ocultar a visualização dos objetos por ela encobertos.

A cada elemento natural ou antrópico que compõe uma paisagem, podem ser associadas uma ou mais características acima descritas, de acordo com suas peculiaridades. A Figura 4 apresenta alguns pontos de referência da imagem do Landsat da região sul do Espírito Santo, com seus elementos naturais e antrópicos.

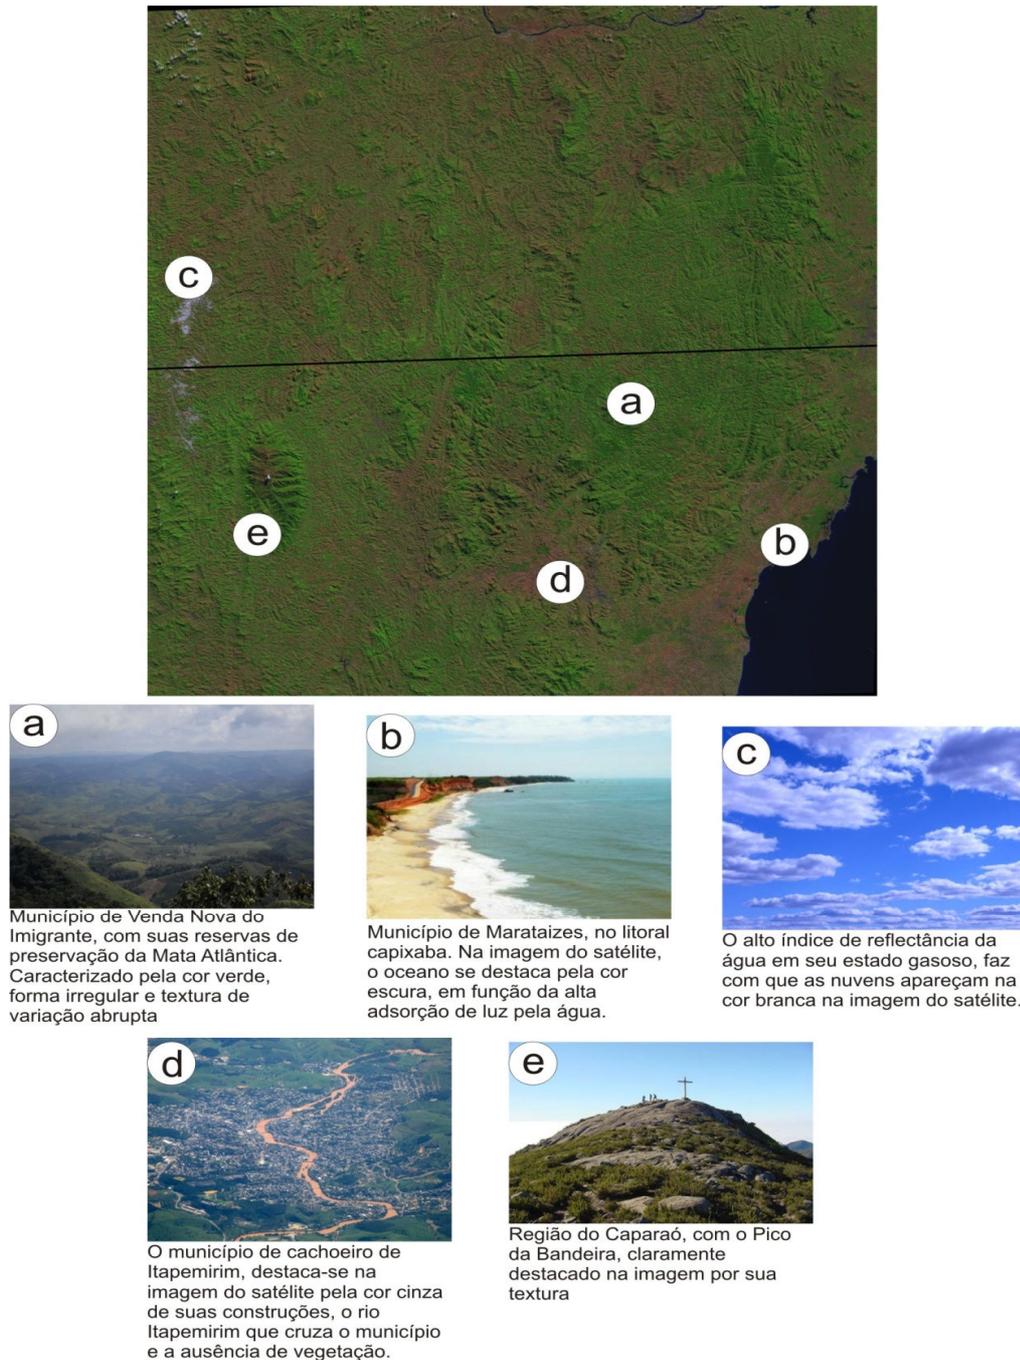


Figura 4 - Imagem do satélite Landsat 5 do sul do Espírito Santo com a identificação dos pontos que correspondem a (a) Mata Atlântica, (b) oceano, (c) nuvens, (d) área urbana, (e) Pico da Bandeira.

Dentre os elementos naturais, há as florestas tropicais, como a Mata Atlântica, caracterizada pelo clima quente e úmido, que reúne formações vegetais diversificadas e heterogêneas. Pelo alto nível de desmatamento, veem-se, normalmente, nas imagens do satélite, apenas fragmentos de sua formação na cor verde, formação irregular e textura de formação abrupta. Também os

mangues podem ser claramente distinguidos dos demais elementos pela sua cor verde escura na proximidade do litoral.

Dentre os ambientes transformados pelo homem, destacam-se os ambientes rurais, cobertos por matas secundárias, pastagens, reflorestamento ou cultivo. Construções esparsas e baixa densidade demográfica também caracterizam esse ambiente, que nas imagens de composição colorida possuem cor verde claro ou avermelhada, pela exposição do solo.

Os ambientes urbanos normalmente apresentam cor cinza nas imagens de composição colorida por causa das suas construções e formação irregular, no caso de cidades construídas sem planejamento ou regulares, quando são cidades planejadas, como é o caso de Brasília.

A energia solar constitui o princípio em que se fundamenta o sensoriamento remoto. A interação da atmosfera terrestre com a radiação solar se dá de duas formas: (a) espalhamento: processo físico que resulta da observação das ondas eletromagnéticas por partículas existentes nas suas trajetórias, ao penetrarem na atmosfera terrestre. Essa obstrução pode ser tanto da energia incidente quanto da reirradiada (refletida); (b) absorção atmosférica: a absorção da radiação solar na atmosfera se dá por meio dos processos de dissociação e fotoionização na alta atmosfera e vibração e transição rotacional de moléculas.

São vários os parâmetros que influenciam na reflectância dos solos, dos quais a literatura cita como mais importantes os óxidos de ferro, a umidade, a matéria orgânica, a granulometria, a mineralogia da argila e o material de origem. Além desses, tem sido citadas a cor do solo, a capacidade de troca catiônica, as condições de drenagem interna do solo, a temperatura, a localização, dentre outros.

A radiação solar interage também com as plantas, sendo que uma parte dessa radiação (aproximadamente 50% do total que chega até a planta) é absorvida pelos pigmentos contidos na folha e participa na síntese de compostos ricos em energia (fotossíntese), altera estruturas moleculares (fotoconversão), acelera reações, como a fotooxidação das xantofilas, ou ainda destrói estruturas de uma molécula. Outra parte é refletida pelas folhas, fenômeno denominado reflexão. Finalmente, uma terceira parte sofre o processo de transmissão, através das camadas de folhas que compõem a copa e daquelas que constituem a folha, como a cutícula, o parênquima lacunoso e o paliçádico (Moreira, 2005).

As quantidades de energia absorvida, transmitida ou refletida pelas folhas das plantas podem diferir de uma espécie para outra ou até mesmo dentro da própria espécie, porque existem, dentre outros, os fatores ambientais que influenciam direta ou indiretamente nesta interação.

A energia absorvida é a de maior interesse nas pesquisas relacionadas à produção vegetal, porque é por meio dela que se podem tirar conclusões a respeito das condições fitossanitárias de determinada cultura agrícola. Como os sensores só registram a energia refletida ou emitida, essa variável normalmente é estimada ou faz-se uma inferência indireta sobre ela utilizando-se as energias absorvida e transmitida.

Os pigmentos foliares, os espaços ocupados pela água e pelo ar e as estruturas celulares com dimensões do comprimento de onda da radiação incidente são os principais mecanismos que influenciam a quantidade de energia eletromagnética refletida pelas folhas.

As comunidades das plantas podem ser quase homogêneas, como áreas agrícolas, ou bastante heterogêneas, como no caso de uma área ocupada por uma mata natural, onde se tem árvores de diferentes portes e espécies.

O conhecimento das propriedades físicas da água é essencial para entender sua influência no comportamento espectral dos demais alvos da superfície terrestre. A água no estado líquido absorve toda a radiação eletromagnética abaixo de 380 nm e acima de 700 nm. Mesmo dentro dessa faixa, a reflectância da água no estado líquido é relativamente pequena, ultrapassando pouco mais de 5%.

2.1.2. O Programa Espacial Landsat

A evolução do SR é consequência do desenvolvimento de setores diversos, como a física, a química, a informática, a geomática, entre outros. Desde a década de 1960, os Estados Unidos vêm investindo em tecnologias nesse setor, inicialmente usadas para apoio às atividades militares do período da guerra fria, logo passaram a ser utilizadas também como ferramentas nas pesquisas aplicadas à agricultura, florestas, geologia, água e meteorologia. Atualmente, diversos países dominam essa tecnologia e a utilizam com os mesmos propósitos.

Um dos programas mais proeminentes de sensoriamento remoto é o Landsat, desenvolvido e gerenciado pela NASA¹ desde a década de 1970. A partir 1972, os satélites Landsat começaram a colher informações sistemáticas sobre a Terra, permitindo que se estudem mudanças naturais e antrópicas na paisagem.

O programa teve início com o lançamento do satélite Landsat 1, em 23 de julho de 1972, que carregava dois instrumentos para executar o monitoramento: um sistema de câmera denominado *Return Beam Vidicon* (RBV) e um sistema de varredura multiespectral (MSS - *Multispectral Scanner System*), que operou até janeiro de 1978, capturando mais de 300.000 imagens da superfície terrestre. O segundo satélite foi o Landsat 2, que operou de janeiro de 1975 a fevereiro de 1982 e carregava os mesmos sensores que seu antecessor. O Landsat 3 foi lançado em 1978 e se tornou operacional a partir de 1979, sob a responsabilidade do NOAA², agência encarregada de operar os satélites meteorológicos. Carregava, entretanto os mesmos sensores que os satélites anteriores (Nasa, 2010).

Os satélites Landsat 4 e 5, lançados respectivamente em 1982 e 1984, apresentaram mudanças significativas em relação aos seus antecessores: abandonou o sistema RBV e junto ao sistema MMS, carregavam um sensor com resolução espacial e espectral superiores, que permitiam uma visão maior e mais detalhada do espectro eletromagnético, graças às suas sete bandas espectrais, três na faixa do visível e quatro no infravermelho. Esse novo instrumento era conhecido como *Thematic Mapper* (TM). Em 1993, houve o lançamento sem sucesso da versão 6 do satélite e em 1999, foi lançado o Landsat 7, carregado com o instrumento de observação terrestre denominado ETM⁺ (*Enhanced Thematic Mapper Plus*). Esse novo sensor se mostrou mais versátil e eficiente para estudos de mudança global, monitoramento e avaliação da cobertura terrestre e maior mapeamento de área que seus antecessores.

O Brasil recebe imagens do satélite Landsat desde 1973, por meio de uma antena da estação de recepção do INPE, localizada em Cuiabá-MT, que é o centro geodésico da América do Sul.

¹ Acrônimo para *National Aeronautics and Space Administration*. Órgão responsável pelos projetos espaciais dos Estados Unidos.

² Acrônimo para *National Oceanic and Atmospheric Administration*.

2.2. Correção Atmosférica

Entre o sensor e o alvo, existe a atmosfera, um meio dinâmico, que influencia diretamente no resultado das imagens geradas, por causa da sua interação com a radiação eletromagnética. Para que esses efeitos sejam atenuados, é necessário que se submeta a imagem a uma correção atmosférica, que se baseia nas características espectrais do sensor e as condições atmosféricas da data e hora da aquisição dos dados da imagem. Após a correção atmosférica, é possível que seja feito o cálculo do índice de vegetação, que se baseia na razão entre as bandas do infravermelho e vermelho e a comparação de imagens de épocas diferentes.

A atmosfera terrestre é um meio complexo e dinâmico, composto, basicamente, de gases e partículas e sujeito às mais diversas mudanças, que necessitam ser compreendidas a fim de que sejam mitigadas. De acordo com Latorre, *et al.* (2002 p. 154), a concentração dos gases possui variações em função da altitude e, conseqüentemente, da pressão e temperatura. Além disso, a composição e a concentração dos gases da atmosfera sofrem influência da posição geográfica e das estações do ano. Também compõem a atmosfera, o vapor d'água e as partículas sólidas e líquidas, com concentrações altamente variáveis.

A interferência atmosférica é um dos principais fatores de degradação nas imagens, muitas vezes comprometendo sua análise e interpretação. A intensidade desse efeito depende do comprimento de onda, portanto, afeta de modo diferente a cada uma das bandas espectrais (Figueiredo, 2005). Parâmetros referentes à data e à hora da passagem do satélite podem ser usados para o cálculo da correção da imagem, porém, como são de difícil mensuração, são pouco usados na prática.

Segundo Mendonza e Hoover (2005), há, atualmente, na literatura, diversos métodos de correção atmosférica baseados em modelos que simulam as propriedades ópticas da atmosfera através de alvos com reflectância conhecida ou por meio de métodos que utilizam feições presentes na própria imagem.

Uma metodologia bastante utilizada para corrigir os efeitos do espalhamento atmosférico seletivo (*Rayleigh*) é a técnica da subtração do pixel

escuro (DOS, de *dark object subtraction*), proposta por Chavez (1988). Essa metodologia assume a existência de objetos escuros na imagem e que possuem valores de reflectância muito próximos de zero. No entanto, esses alvos aparecem na imagem com valores superiores ao real devido ao efeito atmosférico. Portanto, um determinado valor calculado a partir do mínimo valor de ND é atribuído ao espalhamento e deve ser removido de todos os pixels da imagem (Barreto Luiz, *et al.*, 2003). Assim, não é necessário se obter dados sobre as condições atmosféricas na data da obtenção das imagens.

Para a aplicação da correção DOS, a partir da análise do histograma de frequências de ND de uma banda da imagem, de preferência a banda de menor comprimento de onda, um valor de pixel escuro é escolhido. Em seguida, um modelo de espalhamento atmosférico é selecionado e o valor de espalhamento é estimado por banda espectral, sendo os valores de espalhamento estimados normalizados de acordo com os ganhos e *offsets* usados pelo sistema imageador para coletar os dados. A correção é feita pela subtração dos valores estimados para toda a imagem, assumindo um espalhamento uniforme em toda a cena, o que raramente acontece (Chavez, 1988).

2.2.1. Cálculo de Reflectância

No sensoriamento remoto, a classificação das imagens é feita por meio da associação de cada pixel a um tipo de objeto pretendido. A reflectância de cada ponto imageado é traduzida em valores numéricos, denominados números digitais (ND), que unidos, compõem a imagem digital de cada banda espectral em tons de cinza. Entretanto, muitas vezes, o ND, que compõe originalmente as imagens, não é indicado para classificá-las, principalmente, quando se deseja comparar imagens de sensores ou épocas diferentes, isso porque o ND carrega consigo características do momento da obtenção da imagem. Por isso, é necessário que se transforme os valores de ND em valores de reflectância.

A correção pelo método DOS é realizada a partir da estimativa da interferência atmosférica em cada banda espectral, seguida pelos cálculos para transformação do número digital em valores de radiância e, então, para valores de reflectância. Para realizar essa série de cálculos são necessários diversos parâmetros: radiância mínima e máxima, irradiância no topo da atmosfera e

ganho do sensor, parâmetros que variam para cada banda. Além disso, são necessários outros parâmetros que dependem da data da imagem, como a distância Terra-Sol e o ângulo de elevação solar (Gürtler, *et al.*, 2005, p.02).

As variáveis necessárias para o cálculo estão presentes na própria imagem, a saber: o sensor, a data da imagem, o ângulo de elevação solar (em graus) e o ganho para cada banda, quando se tratar de imagens do sensor ETM+.

As equações utilizadas no método DOS, para corrigir os valores de bruma utilizam valores de ganho e *offset* do sensor, modelos de espalhamento relativo, considerando a atmosfera: muito limpa, (λ^{-4}); limpa, (λ^{-2}); moderada, (λ^{-1}); brumosa, ($\lambda^{-0.7}$) e muito brumosa, ($\lambda^{-0.5}$). Quando o valor do número digital (ND) for menor ou igual a 55, usa-se o modelo de espalhamento relativo de λ^{-4} . E que, o valor de bruma utilizado para estimar as condições atmosféricas (fornecido pela banda que tem a maior gradiente de frequência dos números digitais) em todas as faixas espectrais deve ser equivalente a 1% de reflectância do valor do pixel escuro (SILVA, 2004, p.33).

2.3. Índice de Vegetação

Em geral, toda vegetação, em bom desenvolvimento vegetativo, absorve significativamente a radiação na faixa do visível, como energia para o processo de fotossíntese. Por outro lado, esta mesma vegetação reflete fortemente a radiação do infravermelho. A intensidade da absorção do visível e da reflectância do infravermelho é mais acentuada quanto melhor estiver o desenvolvimento da planta. Devido à forte absorção, a radiância correspondente à faixa do visível chega enfraquecida no satélite, enquanto a correspondente ao infravermelho, fortemente refletida pela vegetação, chega com forte intensidade. Esta diferença de intensidades é captada pelo sistema sensor e registrada na imagem digital. Em computador, por meio de operações aritméticas simples, utilizando os níveis de cinza dos pixels, obtém-se um valor numérico, chamado de índice de vegetação (IV) (Figueiredo, 2005).

Dentro dos estudos de Sensoriamento Remoto, a vegetação é um alvo complexo para ser analisado devido à sua não linearidade. A vegetação apresenta variadas propriedades de reflexão foliar em uma mesma planta,

múltiplos componentes refletores, não uniformidade de estrutura inter e intraplantas, além de assentar-se sobre um substrato constituído de solo ou restos vegetais que, por sua vez, apresentam propriedades de reflexão própria, contribuindo no processo de medição para a modulação das propriedades de reflexão da vegetação (Rosendo, 2005). Essa riqueza de diversidade muitas vezes dificulta a observação e classificação dos objetos alvos em estudo. Para minimizar essa diversidade, os índices de vegetação têm sido largamente utilizados na área de sensoriamento remoto como indicador das condições da vegetação da área analisada, mapeamento da vegetação e classificação do uso e ocupação da terra. As medidas de índice de vegetação se baseiam principalmente na reflectância espectral da vegetação referentes às regiões do vermelho e do infravermelho próximo. As medidas de índice de vegetação têm, em geral, associação direta com a quantidade de biomassa, o índice de área foliar, a cobertura do solo, a interceptação da radiação e o rendimento agrícola (Millard et al., 1990). Combinando os índices de vegetação diariamente entre composições de 8, 16 ou 30 dias, cientistas criam mapas detalhados da densidade da vegetação da Terra que identificam onde as plantas estão prosperando e onde estão sob *stress* (Weier e Herring, 2010).

Há vários índices de vegetação descritos na literatura, que podem ter comportamentos distintos, de acordo com características específicas do alvo observado, como a iluminação, a arquitetura do dossel ou o substrato abaixo do dossel. Os índices em uso na literatura são basicamente de dois tipos: os índices baseados em inclinação como o Índice de Vegetação por Diferença Normalizada (NDVI) e o Índice de Vegetação ajustado ao Solo (SAVI) e aqueles baseados em distância, como o Índice de Vegetação Perpendicular (PVI) e o Índice de Vegetação Ponderado (WDVI) (Tanajura *et al.*, 2005).

2.3.1. Índice de Vegetação por Diferença Normalizada (NDVI)

O índice de vegetação mais utilizado é o NDVI (*Normalized Difference Vegetation Index*). Como a maioria dos outros índices de vegetação, o NDVI é calculado com base na razão entre a reflectância nas porções do vermelho (banda 3) e do infra-vermelho próximo (banda 4) do espectro eletromagnético. Essas duas bandas espectrais são escolhidas por serem as mais afetadas pela

absorção de clorofila na vegetação de folha verde e pela densidade de vegetação verde na superfície. Também, porque é nessas bandas que o contraste entre vegetação e solo é maior.

De modo geral, se a radiação refletida na região do infravermelho próximo for maior do que na região do visível, então é provável que a vegetação naquele pixel seja densa e possa conter algum tipo de floresta. Se há pouca diferença na intensidade do visível e do infravermelho próximo refletido, então é provável que a vegetação seja escassa e possa conter área de pastagem ou descampada (Weier e Herring, 2010).

O NDVI é definido pela equação (1)

$$NDVI = \frac{(IVP - V)}{(IVP + V)} \quad (1)$$

Onde:

NDVI = Índice de Vegetação NDVI

IVP = Reflectância referente à região do infravermelho próximo

V = Reflectância referente à região do vermelho

Os sensores TM e ETM+ dos satélites Landsat proveem bandas de imagem do vermelho e do infravermelho próximo, portanto, podem ser usados para gerar conjuntos de dados NDVI, utilizando-se a seguinte equação:

$$(ETM^+)NDVI = \frac{\text{banda 4} - \text{banda 3}}{\text{banda 4} + \text{banda 3}} \quad (2)$$

Embora imagens do sensor AVHRR (*Advanced Very High Resolution Radiometer*) a bordo do satélite NOAA (*National Oceanic and Atmospheric Administration*) sejam mais comumente utilizadas para geração de índice de vegetação, sua resolução é bem menor que dos sensores TM e ETM+ do Landsat (Cgis, 2010).

Para cada pixel da imagem original é gerado o NDVI correspondente, que assume valores entre -1,0 e 1,0. Valores próximos a zero indicam falta de vegetação e valores próximos de 1,0 indicam alta densidade de folhas verdes na região. A Figura 5 ilustra essa diferença.

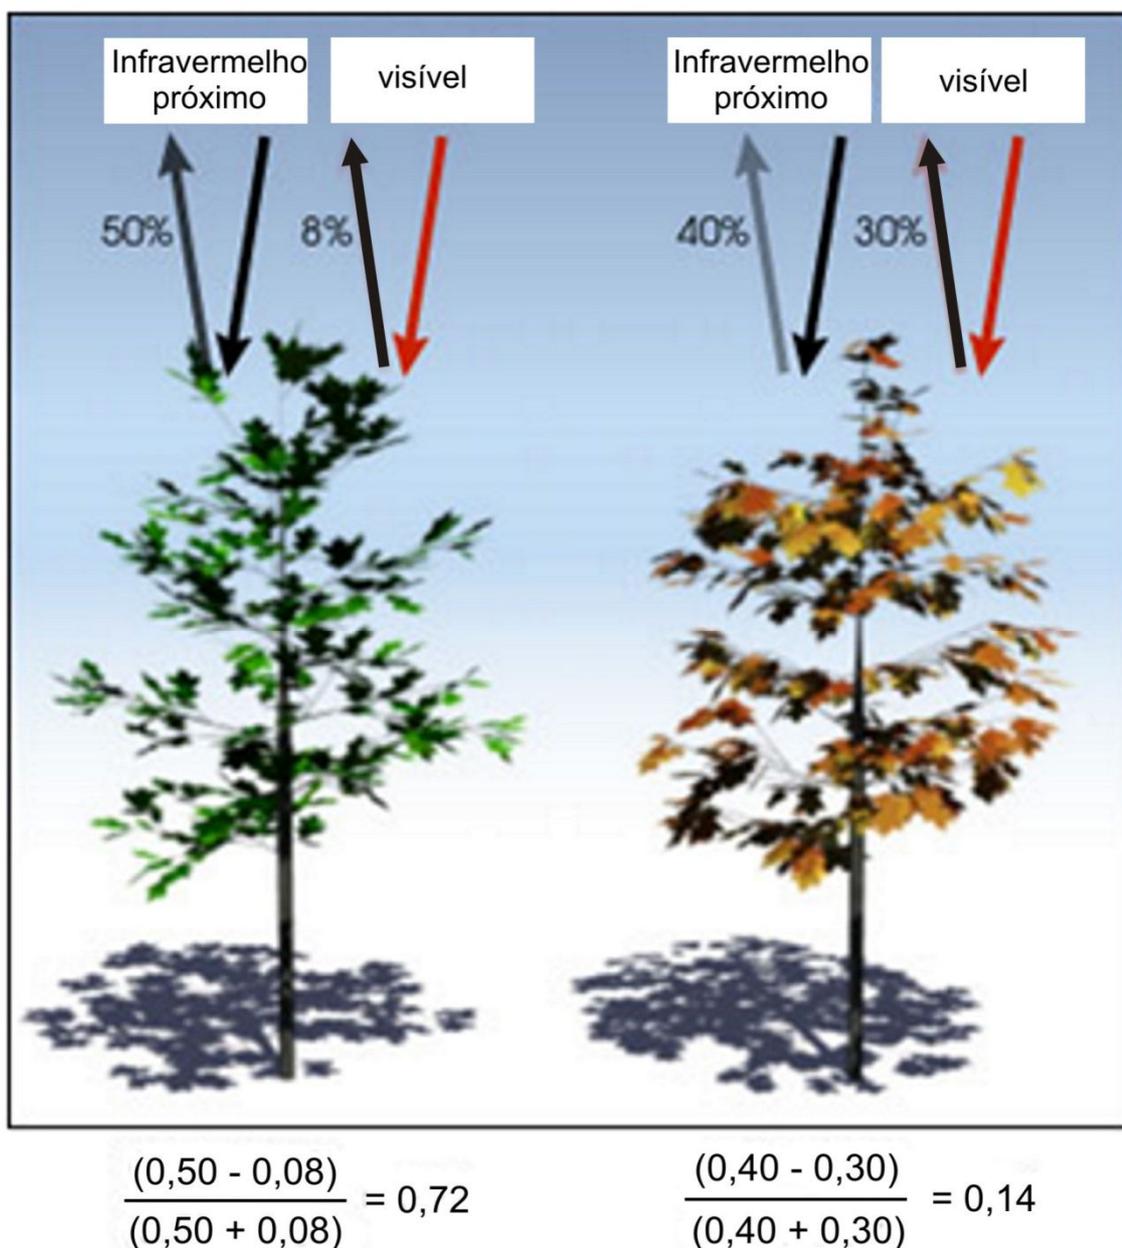


Figura 5 - Ilustração do NDVI calculado para uma região de vegetação saudável (esquerda) e outra de vegetação escassa (direita) (adaptada de Weier e Herring, 2010).

2.3.2. Índice de Realce de Vegetação (EVI)

Esse índice foi desenvolvido com o objetivo de promover a redução das influências atmosféricas e do solo de fundo do dossel no monitoramento da vegetação (Justice *et al.*, 1998).

O EVI pode ser gerado por meio da equação proposta por Huete *et al* (1997):

$$EVI = G \left(\frac{\rho_{IVP} - \rho_V}{\rho_{IVP} + C_1 * \rho_V - C_2 * \rho_A + L} \right) \quad (3)$$

Onde:

EVI é o índice de realce de vegetação;

ρ_{IVP} é a reflectância no infravermelho próximo;

ρ_V é a reflectância no vermelho;

ρ_A é a reflectância no azul;

C_1 é o coeficiente de correção dos efeitos atmosféricos para o vermelho (6);

C_2 é o coeficiente de correção dos efeitos atmosféricos para o azul (7,5);

L é o fator de correção para a interferência do solo (1) e;

G é o fator de ganho (2,5).

Assim como o NDVI, o EVI tem seus valores dentro da faixa -1,0 a +1,0.

2.4. Softwares de Informações Geográficas Existentes no Mercado

Atualmente, há no mercado alguns sistemas de informações geográficas (SIG) que se destinam ao processamento e interpretação de imagens de sensoriamento remoto. A seguir são apresentadas as características de alguns desses softwares.

2.4.1. SPRING

O SPRING, desenvolvido pelo INPE³, é um software de distribuição livre que tem a participação da Embrapa/CNPTIA⁴, IBM Brasil⁵, PUC-Rio/TECGRAF⁶ e PETROBRÁS/CENPES⁷. Possui funções de processamento de imagens, análise espacial, modelagem numérica de terreno e consulta a bancos de dados

³ Instituto Nacional de Pesquisas Espaciais. [HTTP://www.inpe.br](http://www.inpe.br)

⁴ Centro Nacional de Pesquisa Tecnológica em Informação para a Agricultura. <http://www.cnptia.embrapa.br/>

⁵ Centro Latino Americano de Soluções para Ensino Superior e Pesquisa. <http://www.ibm.com/br/pt/>

⁶ Grupo de Tecnologia em Computação Gráfica da PUC-Rio. <http://www.tecgraf.puc-rio.br/>

⁷ Centro de Pesquisa "Leopoldo Miguez". <http://www.petrobras.com.br/pt/>

espaciais (Câmara, 1996). O autor cita ainda que dentre as principais características do SPRING, pode-se destacar: (a) processamento de imagens; (b) análise geográfica; (c) modelagem digital de terreno; (d) modelagem de redes; (e) consulta a bancos de dados relacionais (mapas cadastrais); (f) geração de cartas; (g) intercâmbio de dados; (h) gerenciamento de mapas.

O SPRING é um software bastante difundido no meio acadêmico e nos centros de pesquisas, tendo diversos trabalhos científicos publicados baseados em suas funcionalidades (Câmara *et al.*, 1996), (Lopes, 2003), (Souza e Medeiros, 2005) (Serafini Júnior, 2008) (Silva *et al.*, 2006).

2.4.2. ARCGIS

O ARCGIS é produzido e comercializado pela empresa ESRI⁸ e atualmente encontra-se disponível nas versões *Desktop* (monousuário), *Server* (servidor), *Embedded* (incorporado) e *Mobile* (para dispositivos móveis). A versão desktop é a mais difundida e é composta pelas seguintes aplicações: *ArcCatalog*, *ArcMap*, *ArcGlobe*, *ArcToolbox* e *ModelBuilder*. Há três níveis do produto: *ArcView*, *ArcEditor* e *ArcInfo*, sendo essa última a versão mais completa, com ferramentas de geoprocessamento mais complexas.

As principais funcionalidades do pacote de aplicativos são: (a) cartografia; (b) análise e edição de mapas em camadas; (c) composição de mapas simples; (d) pesquisa a informações geográficas; (e) gravação, visualização e gerenciamento de metadados; (f) definição, exportação e importação de modelos e projetos de bases de dados geográficos (Esri, 2009).

2.4.3. EASI/PACE

O EASI/PACE foi desenvolvido e é comercializado pela empresa canadense PCI Enterprises Inc. O software apresenta funcionalidades de classificação, correção geométrica, ortorretificação, realce, filtragem, edição de vetor com imagem de plano de fundo, visualização e análise de terreno,

⁸ <http://www.esri.com/software/arcgis/index.html>

processamento de imagem de radar, correção atmosférica e análise de dados hiperespectrais (Eoportal.Org, 2009).

O software executa classificação multispectral por meio do algoritmo de classificação supervisionada dos k-vizinhos mais próximos, classificador *fuzzy* não supervisionado, rede de segmentação multi-nível, transformada bidimensional em linha *wavelet* de *Mallat* e modelo linear de mistura espectral (Eoportal.Org, 2009).

2.4.4. ERDAS IMAGINE

O ERDAS IIMAGINE foi desenvolvido e é comercializado pela empresa ERDAS⁹ para criar, gerenciar e processar imagens digitais. É distribuído em três versões distintas: *Imagine Essentials*, *Image Advantage* e *Imagine Professional*, sua versão completa, composta das seguintes funcionalidades: (a) conexão de arquivos por meio de *viewers*; (b) classificação não supervisionada; (c) georeferenciamento de imagens; (d) mosaico de imagens; (e) ortoretificação de imagens; (f) classificação baseada no conhecimento; (g) fusão de imagens; (h) realce espacial, radiométrico e espectral; (i) classificação supervisionada; (j) classificação subpixel de imagem (Erdas, 2010).

2.4.5. ENVI EX

O ENVI EX foi produzido pela empresa americana ITT Visual Information Solution¹⁰ e é comercializado no Brasil pela SulSoft¹¹. Trata-se de um software de tratamento de imagens e dados geográficos que oferece as seguintes funcionalidades: (a) fusão de imagens; (b) detector de feições anômalas; (c) supressão de vegetação para minimizar seus efeitos nas imagens; (d) extração de feições sobre a imagem; (e) classificação de objetos ou feições terrestres com

⁹ Earth Resource Data Analysis System, do grupo americano Exagon. <http://www.erdas.com>

¹⁰ <http://www.itvis.com/>

¹¹ <http://www.sulsoft.com.br>

base nos métodos supervisionados e não supervisionados; (f) detecção de variação temporal; (g) ortorretificação de imagens (Sulsoft, 2010).

2.4.6. IDRISI Taiga

O IDRISI Taiga é comercializado no Brasil pela empresa SulSoft¹², e apresenta, entre suas principais características, a modelagem de tendência temporal de imagens obtidas dos sistemas de observação terrestres, tais como os das plataformas TERRA e Aqua (NASA) e do satélite NASA/JAXA TRMM (*Tropical Rainfall Measuring Mission*). Dentre suas características estão: (a) análise de séries temporais e detecção de mudanças; (b) análise de risco e vulnerabilidade; (c) apoio a decisão tipo multi-critério / multi-objetivo; (d) suporte a decisões, análises de indecisão (incluindo análises bayesianas e fuzzy); (e) simulação de modelamento (incluindo modelamento forçado e análise de fricção anisotrópica) (Sulsoft, 2009).

2.4.7. CLASLITE

Objeto fruto da parceria entre The Carnegie Institution for Science¹³, Fundação Gordon e Betty Moore¹⁴ e Fundação John D. and Catharine T. MacArthur¹⁵, o CLASLITE é um software de uso livre para instituições governamentais, não governamentais (ONGs), aquelas sem fim lucrativos e as acadêmicas, localizadas nas regiões dos Andes-Amazônia e do Escudo das Guianas, na América do Sul (Idesam, 2010). O software tem como objetivo converter imagens básicas de satélite em mapas detalhados, que podem ser estudados para detectar o desmatamento, a extração e outros eventos de perturbação florestal.

¹² <http://www.idrisi.com.br/>

¹³ <http://carnegiescience.edu/>

¹⁴ <http://www.moore.org/>

¹⁵ http://www.macfound.org/site/c.1kLXJ8MQKrH/b.3599935/k.1648/John_D__Catherine_T_MacArthur_Foundation.htm

As áreas onde houver ocorrência recente de corte raso, extração e outra perturbação florestal podem ser identificadas. É possível ainda rastrear tanto o desmatamento quanto o crescimento de floresta secundária (Idesam, 2010).

2.5. Sistemas de Suporte a Decisão

A tomada de decisão consiste na escolha de uma ou mais opções dentre diversas alternativas existentes, seguindo passos previamente estabelecidos e que culminam em uma possível solução para o problema. Os sistemas de suporte a decisão (SSD) são sistemas de informação que auxiliam no processo de tomada de decisão por meio de tratamento de dados complexos, normalmente semiestruturados ou desestruturados. A ênfase de um SSD recai sobre os estilos e as técnicas individuais da tomada de decisão. Um dos modelos mais aceitos de tomada de decisão, foi desenvolvido por Simon (1965) e, divide a fase de tomada de decisão em três estágios: inteligência, projeto e escolha.

No estágio inicial, denominado inteligência, são identificados e definidos os problemas em potencial e/ou as oportunidades. Neste momento, recolhe-se a informação relacionada com a causa e com o escopo do problema. Durante este estágio, os recursos e os obstáculos ambientais são investigados.

No estágio de projeto, são desenvolvidas soluções alternativas para o problema e é avaliada a viabilidade de cada uma delas.

No último estágio, é feita a escolha da alternativa que demanda a melhor solução de um curso de ação, conforme critérios do próprio decisor.

A solução de problema transcende a tomada de decisão e inclui dois novos estágios: o primeiro deles é o estágio de implantação, quando se coloca a solução em prática. Dessa forma neste estágio, determina-se como a escolha será cumprida. Finalmente, o processo de solução de problemas atinge o estágio de monitoramento, quando os decisores avaliam a implantação para verificar, antecipadamente, se os resultados serão alcançados e, ainda para modificar o processo à luz de uma nova informação. Isso pode demandar não só realimentação, mas também um processo de ajuste. Neste caso, podem-se corrigir problemas que não foram detectados quando da escolha da ação a ser executada. A Figura 6 representa o processo de tomada de decisão e, como ele se relaciona com a solução do problema.

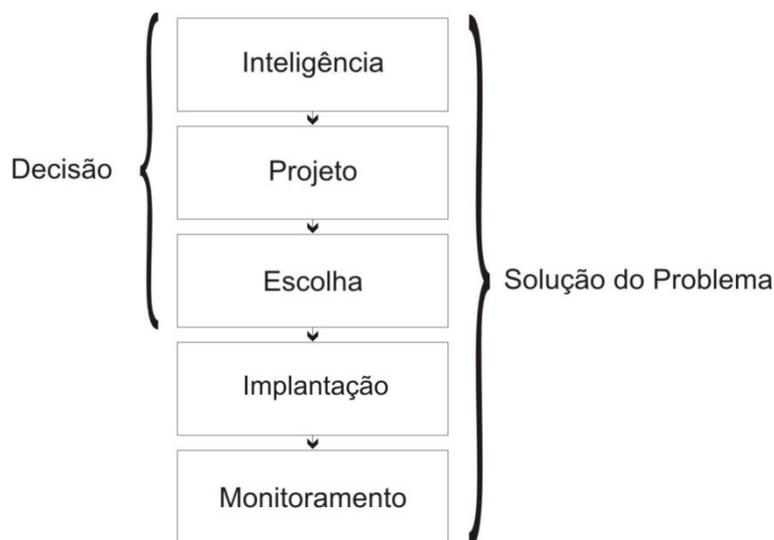


Figura 6 - Os estágios da tomada de decisão e seu relacionamento com a solução do problema (adaptada de Simon, 1965).

Sistemas de suporte a decisão são desenvolvidos para situações não triviais como, por exemplo, a classificação ou categorização de dados. Na classificação de dados, o decisor já conhece o universo de classes às quais um determinado dado de entrada poderá pertencer, como no reconhecimento de padrões de imagens. Já a categorização requer a descoberta das classes existentes e, por conseguinte, a inclusão do dado de entrada na referida classe. Essa técnica é normalmente utilizada quando se deseja identificar perfis de clientes de uma empresa, por exemplo. A lógica de um SSD deve reproduzir o raciocínio humano, capaz de aprender por associação, baseado em aprendizado.

2.6. Redes Neurais Artificiais

2.6.1. Introdução

A computação tradicional é fundamentada em modelos matemáticos e lógica cartesiana, e é capaz de resolver problemas complexos de forma extremamente rápida. Entretanto, o raciocínio humano trabalha de forma diferente, com lógica relativa e com grau de liberdade para tomada de decisão. Os humanos são capazes de decidir, classificar e prever com base em experiências vividas previamente.

As redes neurais artificiais (RNA) constituem uma técnica de desenvolvimento de algoritmo computacional inspirado na estrutura neural dos

seres humanos e que adquirem conhecimento por meio de treinamentos prévios, ou experiência. Essa técnica é de grande importância para processamento em ambientes desestruturados.

Conforme ilustrado na Figura 7, os neurônios de um humano têm um corpo celular central com diversas ramificações, denominadas dendritos. Na outra extremidade, há uma ramificação, normalmente única, denominada axônio. O axônio de um neurônio é interligado aos dendritos de outro neurônio permitindo a transmissão dos pulsos nervosos entre os dois neurônios. Essa transmissão é denominada sinapse.

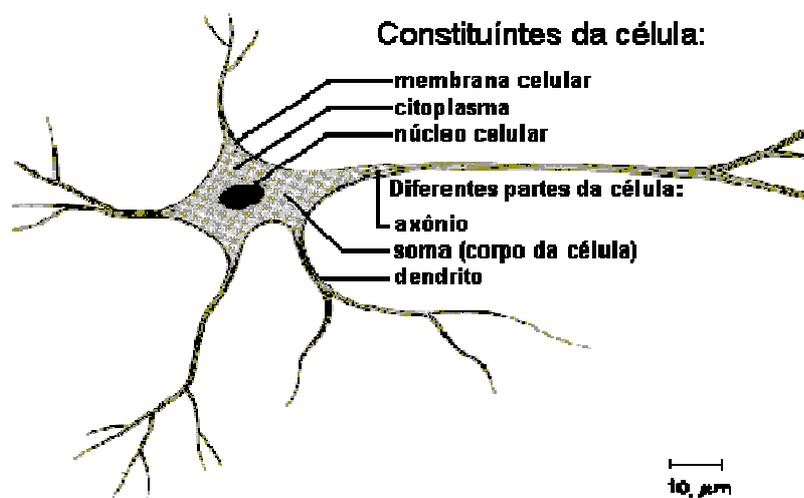


Figura 7 - Esquema da constituinte de uma célula neural (Carvalho, 2009).

As redes neurais artificiais utilizam-se desse princípio em seus algoritmos, por meio de grafos direcionados, compostos por um conjunto de nós ligados uns aos outros por meio de arestas compostas de algumas definições e restrições. Os nós recebem sinais de entrada e multiplicam esse sinal por um peso, que indica suas influências na saída do nó. É produzido um nível de atividade por meio da soma ponderada dos sinais. Se esse nível exceder um limite, a unidade produz uma saída.

O fisiologista Warrem MacCulloch interpretou o funcionamento do neurônio biológico como sendo um circuito de entradas binárias combinadas por uma soma ponderada de valores X_i multiplicados por pesos W_i , produzindo uma entrada efetiva. No modelo geral de neurônio, conforme mostrado na Figura 8, as entradas $X_i W_i$ são combinadas usando uma função $f(a)$, para produzir um estado de ativação do neurônio (correspondente à frequência de descarga do neurônio biológico). As entradas chegam por meio dos dendritos e tem um peso atribuído

pela sinapse (Tatibana e Kaetsu, 2010). Dessa forma, cada nó executa um conjunto simples de instruções e produz uma saída y . A inteligência das RNA encontra-se nas conexões entre essas unidades da rede.

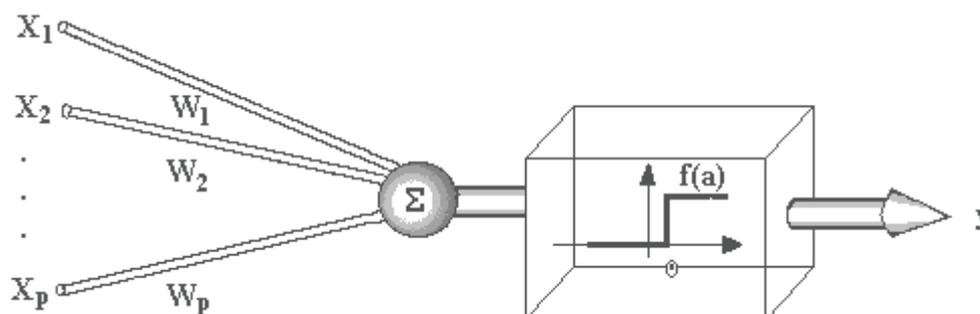


Figura 8 - Modelo de neurônio artificial proposto por McCulloch e Pitts (Tatibana e Kaetsu, 2010).

Os primeiros cientistas a estabelecer um modelo para a neurocomputação foram o fisiologista Warren McCulloch e o matemático Walter Pitts, por meio da publicação de um artigo científico em 1943. Os autores fizeram uma analogia entre células nervosas vivas e o processo eletrônico por meio de uma máquina construída com base no funcionamento do cérebro humano. Esse conhecimento despertou o interesse de vários centros de pesquisas pelo mundo e, em 1987 ocorreu em São Francisco, Califórnia a primeira conferência de RNA em tempos modernos, a IEEE¹⁶ *International Conference on Neural Networks*. Também foi formada a *International Neural Networks Society* (INNS). A partir destes acontecimentos, decorreu a fundação do *INNS journal*, em 1989, seguido do *Neural Computation* e do *IEEE Transactions on Neural Networks*, em 1990 (Carvalho, 2009).

Atualmente, as RNA vêm sendo empregadas com sucesso em vários segmentos científicos, como reconhecimento de padrões, previsão meteorológica, análise comportamental e manipulação de imagens, como as de sensoriamento remoto.

A propriedade mais importante das RNA é a habilidade de aprender de seu ambiente e com isso melhorar seu desempenho. Isso é feito por meio de um processo iterativo de ajustes aplicado a seus pesos, o treinamento. O aprendizado ocorre quando a rede neural atinge uma solução generalizada para

¹⁶ Acrônimo para *Institute of Electrical and Electronics Engineers* (Instituto de Engenheiro Elétricos e Eletrônicos), com sede nos Estados Unidos. <http://www.ieee.org/index.html>

uma classe de problemas. Denomina-se algoritmo de aprendizado a um conjunto de regras bem definidas para a solução de um problema de aprendizado. Existem muitos tipos de algoritmos de aprendizado específicos para determinados modelos de RNA, estes algoritmos diferem entre si principalmente pelo modo como os pesos são modificados (Carvalho, 2009).

2.6.2. Tipo de Redes Neurais Artificiais

Há diversos aspectos passíveis de classificação das redes neurais, dentre elas, podem-se citar a forma de aprendizado, a arquitetura, a topologia e o sentido das sinapses dos neurônios.

Quanto à forma de aprendizado, as RNA podem ser supervisionadas ou não supervisionadas. Diz-se que uma rede neural é supervisionada, quando, de antemão, são passados para a rede parâmetros de como fazer a classificação ou a predição ou de como tomar a decisão a que ela se propõe. À rede são fornecidos vários padrões corretos que permitirão que ela seja treinada e possa posteriormente gerar saídas corretas conforme as entrada recebidas. Nas RNA não supervisionadas, não existe um agente externo que indica a resposta desejada para os padrões de entrada, nesse caso, a própria rede identifica os padrões existentes no conjunto de entradas e classifica-os por meio de agrupamentos por proximidade, dentro de um limite máximo de categorias pré-definidas.

Nenhum tipo de rede é garantido de sempre dar uma resposta absolutamente "correta", especialmente se os padrões são de, alguma forma, incompletos ou conflitantes (Carvalho, 2009).

Quanto à sua arquitetura, uma rede neural pode ter ou não uma retroalimentação. Uma rede em malha aberta ou sem retroalimentação (estática) se caracteriza por não possuir ciclo, e representa geralmente uma relação algébrica não linear entre suas entradas e saídas. Uma rede fechada ou com retroalimentação (dinâmica) possui pelo menos uma malha fechada ou ciclo (Padilha, 2001).

2.6.3. Processo de Execução das Redes Neurais

O primeiro passo, ao se desenvolver uma aplicação de rede neural supervisionada, é estabelecer os conjuntos de dados de entrada para treinamento e para teste da rede. Esses conjuntos de dados devem ser rigorosamente escolhidos a fim de evitar que a rede apenas decore ou vicie em um determinado conjunto de alternativas. É necessário que o treinamento aconteça com dados diversos, mesmo que retratem situações de exceção para que a rede seja o mais precisa possível. Tendo esses dados definidos, pode-se partir para a etapa de definição de configuração da rede, seu paradigma, topologia e os parâmetros de treinamento.

Definidos os parâmetros iniciais, parte-se para o treinamento da rede, quando são ajustados os pesos das conexões. Uma boa escolha dos valores iniciais dos pesos da rede pode diminuir o tempo necessário para o treinamento. Normalmente, os valores iniciais dos pesos da rede são números aleatórios uniformemente distribuídos, em um intervalo definido. A escolha errada destes pesos pode levar a uma saturação prematura. A grande questão do treinamento da rede consiste em saber quando finalizá-lo, para isso, utiliza-se um critério de parada, que pode ser o número máximo de ciclos, como geralmente se faz no algoritmo *backpropagation*. Mas, deve ser considerada a taxa de erro médio por ciclo e a capacidade de generalização da rede. Pode ocorrer que em um determinado instante do treinamento a generalização comece a degenerar, causando o problema de *over-training*, ou seja, a rede se especializa no conjunto de dados do treinamento e perde a capacidade de generalização (Tatibana e Kaetsu, 2010). A conclusão do treinamento se dará quando a rede apresentar uma taxa de erro aceitável para o perfil do problema estudado.

Após o treinamento, faz-se então o teste da rede com um conjunto de dados estabelecido previamente. Nessa etapa, avalia-se o desempenho da rede e seu comportamento em situações de exceção. Com as etapas anteriores concluídas, a rede está apta, então, para ser utilizada em produção, em um *software* próprio.

Várias soluções utilizando RNA têm sido aplicadas com sucesso nas mais diversas áreas da produção vegetal, como para a estimativa da evapotranspiração de referência e do balanço hídrico (Sugawara, 2008).

2.6.4. Redes Neurais para Processamento de Imagens

Jayas *et al.* (2000) realizaram uma revisão bibliográfica sobre a aplicação de RNA como classificadores de imagens para aplicação na Engenharia Agrícola e concluíram que existe grande número de trabalhos publicados, utilizando diversas técnicas de processamento de imagens e de redes neurais para a classificação de imagens, porém a falta de integração entre essas duas técnicas ficou evidente. Finalmente, chegaram à conclusão que o conceito de processamento de imagens pode ser combinado com o de redes neurais classificadoras para serem usados em conjunto em sistemas de visão artificial para aplicações na agricultura.

Há casos em que um único algoritmo de RNA não é suficiente para realizar a classificação das imagens de sensoriamento remoto de forma satisfatória. Nesse caso, são utilizados classificadores híbridos para a solução (Luo e Mountrakis, 2010).

Beluco (2002) e Angelo (2000) utilizaram-se de uma rede neural *Multi-Layer Perceptron* com *BackPropagation* supervisionada para classificação de imagens de sensoriamento remoto baseada em textura, na região de Porto Alegre, RS. Com essa solução, foi possível classificar as áreas de água, urbana e de vegetação.

Todt (1998) utilizou imagens de satélite para a identificação de espécies vegetais (Mata Nativa, Eucalyptus e Acácia) em uma região próxima aos municípios de General Câmara, Santo Amaro e Taquari, no Estado do Rio Grande do Sul. Foi feita uma comparação qualitativa e quantitativa dos resultados obtidos pelo método de Máxima Verossimilhança Gaussiana (método de inferência estatística paramétrico e supervisionado que utiliza amostras de treinamento) e por uma Rede Neural Artificial Multinível com *BackPropagation* na classificação da área de estudo. Foram constatados valores de acurácia superiores ao Método de Máxima Verossimilhança Gaussiana.

Almeida *et al* (2008) utilizaram com sucesso uma Rede Neural Artificial supervisionada com *backpropagation* para classificar a utilização da área urbana do município de Piracicaba, SP, entre os anos de 1985 e 1999.

Pradhan e Lee (2010) utilizaram RNA com sensoriamento remoto para analisar a susceptibilidade dos deslizamentos de encostas em uma região da

Malásia e sua técnica apresentou uma precisão de 83%, considerado satisfatório pelo autor.

Chen (2008) apresentou uma solução para mapear a concentração de carbono em solo orgânico utilizando uma RNA para analisar imagens de SR com agrupamento de áreas de plantio com custo inferior à técnica de amostragem.

2.6.5. Avaliação da Precisão da Classificação dos Dados

O processo de classificação dos dados não é preciso e, portanto sua acurácia deve ser avaliada a fim de se mensurar o nível de confiança do método utilizado.

Na classificação de imagens de sensoriamento remoto, a acurácia do classificador normalmente é medida comparando a verdade terrestre capturada *in loco* ou por meio de imagens aéreas de alta definição com o resultado apresentado por ele pixel a pixel. Um dos métodos mais indicados para avaliar a exatidão da classificação dos dados dos sensores remotos é a análise da matriz de confusão (Chagas, 2006) (Santos *et al*, 2011).

2.6.6. Matriz de Confusão

A matriz de confusão ou matriz de erro é uma matriz quadrada cujas linhas correspondem à verdade terrestre e as colunas correspondem às classes obtidas pela rede neural. Na diagonal principal, são apresentados os números de pixels classificados corretamente. Ribeiro (2003) destaca que a matriz de erro favorece a visualização dos resultados da classificação e expressa a relação entre os dois tipos de erros associados ao sistema de classificação: os de inclusão (um pixel que não pertence à classe de interesse foi a ela atribuído) e de omissão (quando um pixel que pertence à classe de interesse não foi a ela atribuído).

A Tabela 1 apresenta uma representação geral de uma matriz de confusão:

Tabela 1 - Representação Geral de Uma Matriz de Confusão

Classe	Predita C ₁	Predita C ₂	...	Predita C _k	Total
Verdadeira C ₁	M(C ₁ ,C ₁)	M(C ₁ ,C ₂)	...	M(C ₁ ,C _k)	T(Verdadeira C ₁)
Verdadeira C ₂	M(C ₂ ,C ₁)	M(C ₂ ,C ₂)	...	M(C ₂ ,C _k)	T(Verdadeira C ₂)
...					
Verdadeira C _k	M(C _k ,C ₁)	M(C _k ,C ₂)	...	M(C _k ,C _k)	T(Verdadeira C _k)
Total	T(Predita C ₁)	T(Predita C ₂)	...	T(Predita C _k)	Total Geral

2.6.7. Coeficiente Kappa

O coeficiente ou índice kappa é um indicador de acurácia dos valores categorizados com relação à verdade terrestre presentes na matriz de confusão. Seu resultado varia entre 0 e 1 que representam, respectivamente péssima e ótima concordância entre os valores da matriz. Segundo Congalton e Green (2008), o resultado obtido pela análise Kappa pode ser dividido em três grupos: um valor maior que 0,80 (i.e., >80%) representa forte aceitação; um valor entre 0,40 e 0,80 (i.e., 40-80%) representa aceitação moderada; e um valor abaixo de 0,40 (i.e., <40%) representa baixa aceitação.

A estimativa de máxima verossimilhança de Kappa é dada pela equação:

$$\hat{K} = \frac{P_0 - P_c}{1 - P_c} \quad (4)$$

Onde, P₀ representa a exatidão global, ou seja, o número total das unidades classificadas corretamente, presente na diagonal principal da matriz de confusão e é calculada pela equação (5).

$$P_0 = \sum_{i=1}^m P_{ii} \quad (5)$$

Onde,

P₀ = exatidão global;

P_{ii} = valores da diagonal principal;

m = número de classes da matriz.

Aqui não estão apresentadas as exatidões individuais de cada classe, mas para todo o mapa. Para a análise individual de cada classe, basta dividir o

número de unidades amostrais classificadas corretamente em uma classe pelo número total de amostras de referência dessa classe.

P_c representa a proporção marginal da linha i e da coluna i , em relação ao total de unidades:

$$P_c = \sum_{i=1}^k P_{i+} P_{+i} \quad (6)$$

Onde P_{i+} e P_{+i} são, respectivamente, proporções marginais da linha i e da coluna i .

3. MATERIAL E MÉTODOS

3.1. Características Funcionais do Software

A ferramenta Ative tem como característica geral fazer a classificação de imagens do satélite Landsat 7, instrumento ETM+ e Landsat 5, instrumento TM em regiões próximas ou com as mesmas características da região sul do estado do Espírito Santo, que compõe a banda 216/74. Essa classificação permite monitorar a ocupação do solo e assim contribuir para o desenvolvimento sustentável e a preservação dos recursos naturais. O software utiliza-se de ferramentas de geotecnologias, sensoriamento remoto e sistemas inteligentes, como imagens de satélite, sistemas de informações geográficas e serviço de consulta.

Os mapas e as imagens georreferenciadas da região são fornecidos gratuitamente pela web, para que os empreendedores elaborem seus projetos de forma mais eficiente e segura, garantindo a sustentabilidade ambiental. Pretende-se que o resultado desse trabalho seja uma ferramenta valiosa para apoiar e ampliar a capacidade de pesquisadores, órgãos governamentais e não governamentais (ONGs) e instituições acadêmicas que se dedicam ao estudo de mudanças climáticas e ecossistemas dinâmicos para que possam mapear e monitorar as paisagens utilizando imagens obtidas de satélite.

As imagens obtidas serão tratadas em um processo pixel-a-pixel para a correção atmosférica dos níveis de cinza de cada ponto da imagem em valor de reflectância do alvo pelo método de subtração de objeto escuro (DOS).

O processo de classificação está dividido em três etapas sequenciais. Inicialmente, são extraídos os números digitais das bandas 1 a 5 e 7 da imagem e realizada a correção atmosférica com o cálculo dos valores de reflectância baseado no método DOS, proposta por Chavez (1988). A Tabela 2 apresenta as principais aplicações das imagens de cada banda espectral e justifica a escolha no presente trabalho. Com base nos valores de reflectância das bandas 3 e 4, é calculado o índice NDVI para cada ponto da imagem. A segunda etapa consiste na classificação pixel-a-pixel por um classificador neural. A acurácia da RNA é medida utilizando o Coeficiente Kappa. A terceira e última etapa consiste na apresentação dos resultados por meio de imagem, tabela e gráfico. A seguir, cada uma dessas etapas é descrita detalhadamente.

Tabela 2 - Principais aplicações das bandas espectrais do sensor TM (adaptado de Galo *et al*, 2002)

Bandas espectrais	Intervalo espectral (μM)	Principais aplicações
TM1	0,45 – 0,52	Mapeamento de águas costeiras; Diferenciação entre solo e vegetação; Diferenciação entre coníferas e folhosas.
TM2	0,52 – 0,60	Reflectância da vegetação verde sadia.
TM3	0,63 – 0,69	Absorção pela clorofila; Diferenciação entre espécies vegetais.
TM4	0,76 – 0,90	Levantamento da biomassa vegetal; Delineamento de corpos d'água.
TM5	1,55 – 1,75	Medidas de umidade de vegetação; Diferenciação entre nuvens e neve.
TM6	10,4 – 12,5	Mapeamento de estresse térmico em plantas; Outros mapeamentos térmicos.
TM7	2,08 – 2,35	Mapeamento hidrotermal

3.2. Correção Atmosférica

O presente trabalho utilizou o método de correção atmosférica DOS (*Dark Object Subtraction*) proposto por Chavez (1988), no qual, a interferência atmosférica em cada banda é estimada diretamente a partir do ND da imagem do satélite e a absorção atmosférica é ignorada. Em um primeiro momento, é montado o histograma com a frequência dos valores dos pixels da banda 1 da

imagem para que sejam calculados o crescimento máximo, o ND inicial, a situação atmosférica e o modelo de espalhamento da imagem. O crescimento máximo entre um ND e o próximo indica o ND inicial para o cálculo do espalhamento atmosférico. A situação atmosférica e o modelo de espalhamento são baseados no ND inicial, conforme apresentado na Tabela 3. Nesse método, o usuário seleciona o modelo de espalhamento relativo que melhor representa as condições atmosféricas na hora da captura da imagem (Chavez, 1988). O valor sugerido, nesse caso, corresponde ao ND cuja frequência acumulada no histograma obteve o crescimento relativo mais abrupto em relação ao seu sucessor na tabela. A Figura 9 apresenta o diagrama de atividades das etapas de correção atmosférica das imagens.

Tabela 3 - Limiões de números digitais, situação atmosférica para os diferentes valores de pixel escuro na banda 1 e o modelo de espalhamento relativo sugerido. Fonte: Chavez (1988)

ND inicial (do pixel escuro na banda 1)	Situação atmosférica	Modelo de espalhamento
< 56	Muito Limpa	λ^{-4}
≥ 56 e < 76	Limpa	λ^{-2}
≥ 76 e < 96	Moderada	λ^{-1}
≥ 96 e < 116	Com neblina	$\lambda^{-0.7}$
≥ 116	Com muita neblina	$\lambda^{-0.5}$

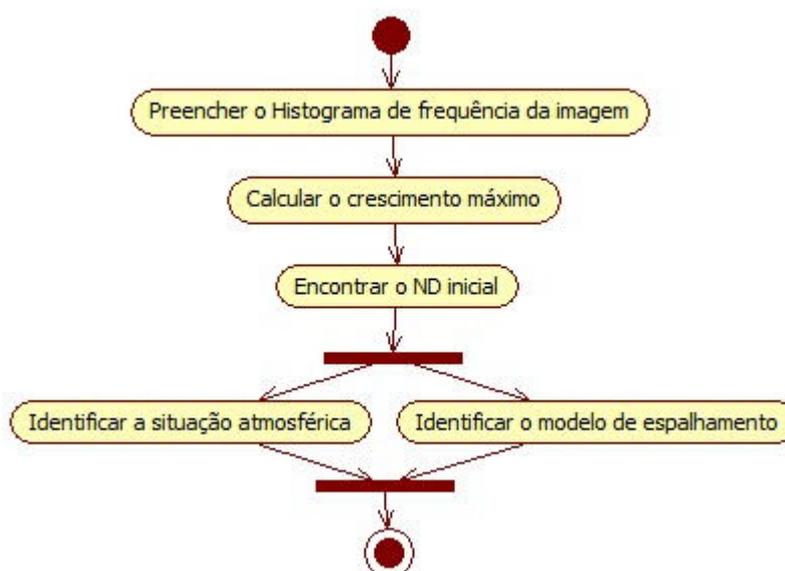


Figura 9 - Diagrama de atividades das etapas de correção atmosférica das imagens.

Na segunda etapa do processo, os parâmetros sensor, data da imagem e ângulo de elevação solar referentes à imagem propriamente dita são informados ao sistema. Todas essas informações podem ser extraídas dos arquivos XML¹⁷ que acompanham a própria imagem. No caso de sensor ETM+, devem ser informados também os valores de ganho de cada banda.

Os passos seguintes constituem o processo de cálculo do valor de reflectância para cada banda com base nos valores da banda 1. Inicialmente é calculado o espalhamento. Na banda 1, que é a banda de referência, esse valor é obtido com base apenas na subtração do equivalente em ND a 1% de reflectância do ND inicial. Nas demais bandas, os valores de espalhamento devem ser ajustados para os diferentes ganhos e *offsets* usados pelo sistema imageador para coletar os dados, que podem ser obtidos respectivamente pelas equações (7) e (8):

$$\text{ganho} = \text{ND}_{\max} / (L^{\max}_{\text{ind}} - L^{\min}_{\text{ind}}) \quad (7)$$

$$\text{offset} = -(\text{ND}_{\max} / (L^{\max}_{\text{ind}} - L^{\min}_{\text{ind}})) * L^{\min}_{\text{ind}} \quad (8)$$

Onde:

$$\text{ND}_{\max} = 255 \text{ e};$$

L é um parâmetro fixo dos sensores TM e ETM+, extraído da Tabela 4.

Tabela 4 - Parâmetros dos sensores TM e ETM+ Fonte: (a) Esa (2012) (b) Nasa (2012)

Banda	TM Landsat 5 (a)		ETM+ Landsat 7(b)							
	L ^{MIN}	L ^{MAX}	Antes de 1/7/2000				Depois de 1/7/2000			
			Baixo ganho L ^{MIN}	Alto ganho L ^{MAX}	Baixo ganho L ^{MIN}	Alto ganho L ^{MAX}	Baixo ganho L ^{MIN}	Alto ganho L ^{MAX}		
1	-1,5	185	-6,2	297,5	-6,2	194,3	-6,2	293,7	-6,2	191,6
2	-3,1	342	-6	303,4	-6	202,4	-6,4	300,9	-6,4	196,5
3	-2,7	245	-4,5	235,5	-4,5	158,6	-5	234,4	-5	152,9
4	-2,5	270	-4,5	235	-4,5	157,5	-5,1	241,1	-5,1	157,4
5	-0,45	36	-1	47,7	-1	31,76	-1	47,57	-1	31,06
7	-0,3	19	-0,35	16,6	-0,35	10,932	-0,35	16,54	-0,35	10,8
8	-	-	-5	244	-5	158,4	-4,7	243,1	-4,7	158,3

Valores em watts/(m²*esterradiano*µm)

O ganho, entretanto deve ser normalizado, tendo como base a banda 1, de acordo com a equação (9):

$$\text{ganho_normalizado} = \text{ganho}_i / \text{ganho}_1 \quad (9)$$

¹⁷ Acrônimo para *extensible markup language*. Tipo de arquivo que descreve tipos de dados diversos, usado para intercambiar informações

Outro dado necessário é a relação entre a banda em estudo e a banda 1, denominado fator λ e obtido pela equação (10).

$$\text{Fator } \lambda = \lambda_{ind}^{exp} / \lambda_1^{exp} \quad (10)$$

Onde:

λ = comprimento de onda médio da banda correspondente, conforme Tabela 5.

exp = expoente de λ de acordo com o modelo de espalhamento apresentado anteriormente na Tabela 3.

Tabela 5 - Parâmetros de ganho e *offset* para cálculo do espalhamento do sensor

Banda	ganho	offset	λ	λ^{-2}	% espalhamento	Fator λ	Ganho normalizado
1	1,289181	7,992922	0,485	4,251249	36,155%	1,000000	1,000000
2	1,256777	8,043371	0,56	3,188776	27,119%	0,750080	0,974864
3	1,614946	8,074731	0,66	2,295684	19,524%	0,540002	1,252692
4	1,035743	5,282291	0,83	1,451589	12,345%	0,341450	0,803412
5	7,953837	7,953837	1,65	0,367309	3,124%	0,086400	6,169682
7	22,869955	8,004484	2,215	0,203823	1,733%	0,047944	17,739910

λ = comprimento de onda médio da banda

Com os valores acima calculados, pode-se, então obter o valor do espalhamento e do espalhamento relativo, respectivamente pelas equações (11) e (12):

$$\text{espalhamento} = (PE - ND_{(1\% \text{ reflect})} - \text{offset}_1) * \text{Fator } \lambda \quad (11)$$

$$\text{espalhamento} + \text{offset} = (\text{ganho_normalizado} * \text{espalhamento}) + \text{offset} \quad (12)$$

Onde:

PE = número digital inicial;

$ND_{(1\% \text{ reflect})}$ corresponde a 1% da reflectância em ND para a banda 1, calculado pela equação (13):

$$ND = (0,01 - i_1) / j_1 \quad (13)$$

Os valores dos parâmetro i e j são definidos respectivamente nas equações (14) e (15):

$$i = ((\pi * d^2) * L_{ind}^{min}) / (E_{sun} * \cos(\text{zen})) \quad (14)$$

$$j_{ind} = ((\pi * d^2) * ((L_{ind}^{max} - L_{ind}^{min}) / d^{max})) / E_{sun} * \cos(\text{zen}) \quad (15)$$

Onde:

$$d^2 = (1 - (0,01674 * \cos(\pi/180 * 0,9856 * (\text{dia_do_ano} - 4))))^2 \quad (16)$$

E_{sun} é um parâmetro do sensor correspondente à irradiância da banda, apresentado na Tabela 6.

$\cos(\text{zen})$ = cosseno do ângulo zenital da elevação solar.

Tabela 6 - Parâmetro do sensor correspondente à irradiância da banda

Banda	E (watts/m ² *μm)
1	1969
2	1840
3	1551
4	1044
5	225,7
7	82,07

Com base nos valores acima descritos, é possível, finalmente, realizar o cálculo da reflectância, apresentado na equação (17):

$$\text{reflectância} = j_{ind} * (ND - nd(\text{esp})) \quad (17)$$

As etapas acima descritas estão ilustradas no diagrama de atividades apresentado na Figura 10:

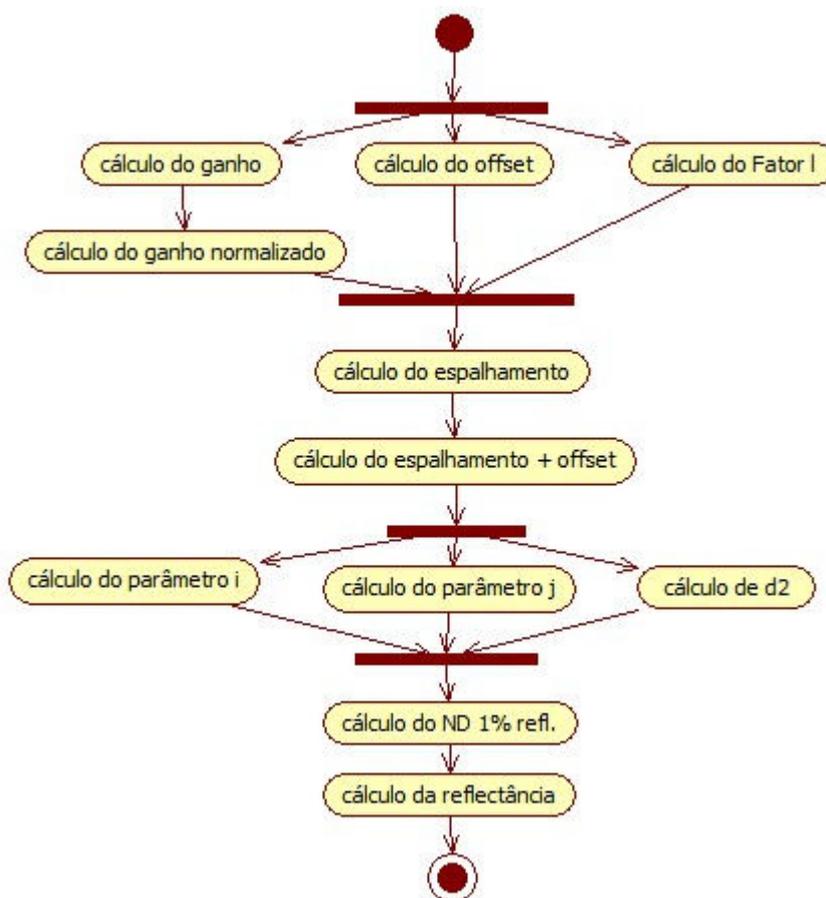


Figura 10 - Diagrama de atividades das etapas que compõem o processo de cálculo da reflectância.

O passo final consiste na obtenção do NDVI com base nos valores de reflectância dos pontos, definido pela equação (18):

$$NDVI = \frac{(IVP - V)}{(IVP + V)} \quad (18)$$

Onde:

NDVI = Índice de Vegetação NDVI

IVP = Reflectância referente à região do infravermelho próximo, obtido pela banda 4;

V = Reflectância referente à região do vermelho, obtido pela banda 3.

3.3. Área de Estudo

A área utilizada para treinamento e teste engloba parte das microrregiões do Polo Cachoeiro (municípios de Cachoeiro de Itapemirim e Jerônimo Monteiro), Caparaó (município de Dorés do Rio Preto), Metr pole Expandida Sul (municípios de Itapemirim, Marataizes e Iconha) e Sudoeste Serrano (município de Venda Nova do Imigrante). Essas regi es apresentam as caracter sticas t picas de uma regi o remanescente da Mata Atl ntica, com fragmentos de floresta tropical, rios e nascentes,  reas de monocultura e pastoril, solo exposto e  reas urbanas. A imagem utilizada para fins de estudo   proveniente do Sat lite Landsat 5, instrumento TM, banda 216/74. Da imagem utilizada, foram feitos recortes para treinamento e teste da RNA, conforme Tabela 7.

Tabela 7 - Recortes de imagens utilizados para treinamento e teste da RNA

Classe	Regi�o (Munic�pio)	�rea de recorte (em <i>pixel</i>)	Tamanho (em <i>pixel</i>)
�rea Urbana	Cachoeiro de Itapemirim	15x18	270
	Jer�nimo Monteiro	16x9	144
	Marataizes	13x11	143
Fragmento de Floresta	Itapemirim	24x12	288
	Cariacica	15x12	180
	Cachoeiro de Itapemirim (Pacotuba)	14x7	98
Culturas	Itapemirim	22x18	396
	Iconha	9x5	45
	Alegre	13x8	104
Solo Exposto e Pastagens	Itapemirim	27x14	378
	Jer�nimo Monteiro	13x10	130
	Cachoeiro de Itapemirim (Itaoca Pedra)	12x10	120

Água	Cachoeiro de Itapemirim (Rio Itapemirim)	7x7	49
	Oceano Atlântico	11x9	99
	Vitória	22x19	418

3.4. Algoritmo de Classificação

O algoritmo de classificação foi implementado em linguagem de programação Delphi 2009, com RNA multinível com *backpropagation* e classificação supervisionada num processo pixel a pixel. Foram selecionados recortes da imagem original cujas feições são capazes de representar cada uma das classes abordadas na pesquisa, a saber: urbana, fragmentos de floresta, culturas solo exposto/pastagem e água. A RNA passou inicialmente por um processo de treinamento com dados retirados de amostra de cada classe de paisagem da imagem original. Dessa forma, foi possível calcular os pesos sinápticos para o processo de classificação propriamente dito. Posteriormente, foi realizado o processo de teste da rede, utilizando outra massa de dados. Nessa etapa, foram aplicados os pesos sinápticos aos dados de entrada, a fim de se obter a classe calculada de cada pixel. Para cada pixel processado, a rede neural calculou o grau de pertinência em uma das cinco saídas possíveis. A saída, cujo grau de pertinência obteve o maior valor, classificou o pixel. Essa solução se deve à dificuldade de se atingir um valor exato de classificação, então, se aceita uma margem de erro de acordo com a especificidade de cada problema.

3.5. Arquitetura da Rede Neural Artificial Utilizada

A arquitetura da RNA foi inicialmente definida com 3 camadas: a primeira camada, ou camada de entrada, composta por 7 neurônios, com os valores dos índices de reflectância das bandas 1 a 5 e 7 e pelo índice de vegetação; a segunda camada, também denominada de camada intermediária, teve sua estrutura definida durante o processo de treinamento da RNA e a camada de saída foi composta por 5 neurônios, cada um, representando uma das 5 saídas esperadas: áreas urbanas, fragmentos de florestas, culturas, solo exposto e água.

Os valores de reflectância na camada de entrada passaram por um pré-processamento para a correção atmosférica e foram calculados pelo método DOS, proposto por Chavez (1988) e o índice de vegetação utilizado foi o NDVI, definido por Weier e Herring (2010).

O treinamento da RNA é um processo cíclico no qual, a cada ciclo, os padrões de treinamento são apresentados à RNA, a fim de que se façam atualizações nos pesos sinápticos. Não há na literatura nenhuma definição do número ideal de ciclos na etapa de treinamento. Sabe-se, entretanto, que um número excessivo de ciclos pode levar a rede à perda do poder de generalização (*overfitting*). Por outro lado, com um pequeno número de ciclos a rede pode não chegar ao seu melhor desempenho (*underfitting*). No presente trabalho, foram feitos testes com diversos números de ciclos até se chegar a um valor satisfatório. A condição de parada foi o número máximo de ciclos.

A taxa de inércia, também denominado *momentum*, é um parâmetro ajustável que define a taxa de atualização dos pesos da rede. Este dado determina a porcentagem dos pesos sinápticos que será aproveitada da época de treinamento anterior. Durante o processo de treinamento, foram testados todos os valores para taxa de inércia até que se atingisse o valor mais estável.

A taxa de aprendizagem é definida como a quantidade de modificação dos pesos que levam a um nóculo de saída a cada vez que um padrão é apresentado à rede. Esses pesos são levemente modificados durante o aprendizado na direção requerida para produzir um menor erro na próxima vez que o mesmo padrão for apresentado. Por exemplo, se um taxa de aprendizagem é igual a 0,5, a mudança de peso é só 50% do erro. Quanto maior a taxa de aprendizagem, maiores as mudanças de pesos, e mais rápido o aprendizado será procedido. Oscilação ou não convergência pode ocorrer se a taxa de aprendizagem é muito grande (Guahyba, 2011). A escolha da taxa de inércia mais estável aconteceu de forma empírica, pela combinação de valores de ciclos, taxa de inércia e taxa de aprendizagem.

Os valores dos pesos encontrados são armazenados em um arquivo denominado arquivo de conhecimento, e são utilizados na etapa de teste.

Ao final da etapa de teste da rede neural, foi montada a matriz de confusão e, com base em seus valores, foi calculado o índice Kappa que,

segundo Congalton e Green (2008), deve atingir o valor mínimo de 80% para que a rede seja considerada boa.

3.6. Geração da Imagem Classificada

Após a definição das etapas de treinamento e teste terem apresentado resultados satisfatórios, a rede neural se mostrou apta a realizar o processamento da imagem propriamente dito.

Para o presente estudo foram escolhidos recortes da região compreendida entre as coordenadas 20° 48' e 20° 53' de latitude Sul e 41° 9' e 41° 4' de longitude Oeste, que compreende o município de Cachoeiro de Itapemirim e está representada na Figura 11. Os recortes foram extraídos de imagens do sensor TM do satélite Landsat 5, de quatro datas distintas: 09/05/2008, 12/05/2009, 15/05/2010 e 18/05/2011. Para cada um dos recortes, foi feita a classificação da imagem de satélite e gerada a imagem classificada.



Figura 11 - Composição RGB da imagem do sensor TM que compreende o município de Cachoeiro de Itapemirim.

Os dados de cada ponto das imagens foram armazenados no banco de dados do software e utilizados para a confecção do gráfico de uso e ocupação do solo, conforme apresentado na Figura 12.

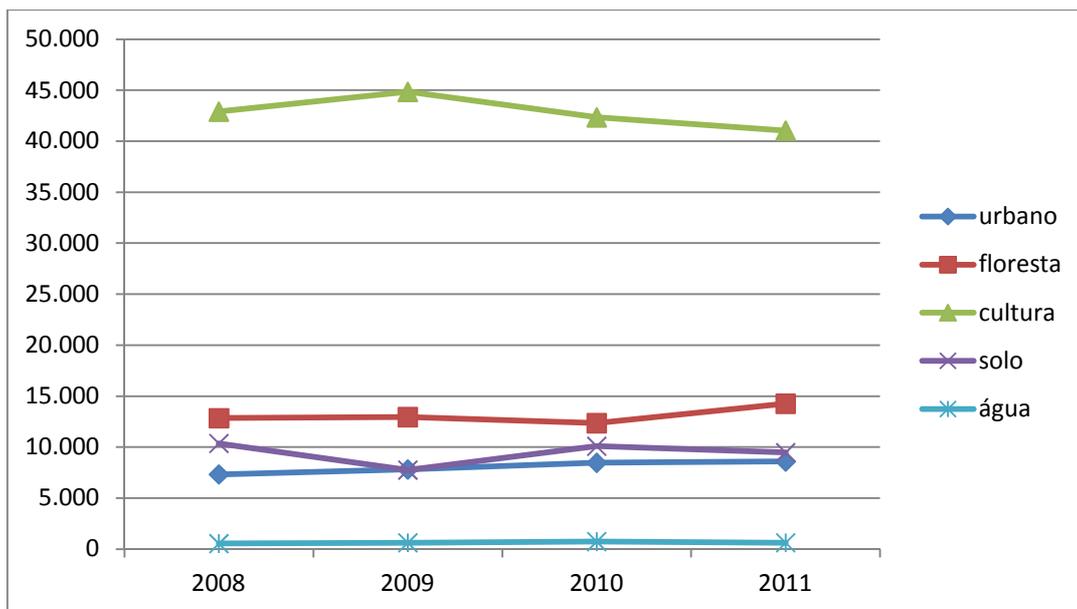


Figura 12 - Gráfico de uso e ocupação do solo.

4. RESULTADOS E DISCUSSÕES

4.1. Correção Atmosférica

Nesse ponto será apresentado um exemplo dos cálculos realizados para transformação no ND 13 da banda 2 em reflectância dos dados da imagem do sensor TM da imagem de 23/05/2007. Os parâmetros informados ao sistema, conforme observado na Figura 13, foram:

Sensor: TM

Data da imagem: 23/05/2007

Ângulo de elevação solar: 50,35706694°

Parâmetros para Cálculo de Reflectância

Cálculo dos parâmetros i e j para transformação do número digital para reflectância não corrigida e cálculo do Multiplicador para transformação dos valores de reflectância em imagem digital, mantendo a amplitude inicial do histograma, ou seja, sem truncamento dos dados e sem saturação

Calcular

Tabela 1: Dados da Imagem

Sensor: TM
 Data da Imagem: 23/05/2007
 Dia do Ano: 143
 Ângulo de Elevação Solar (graus): 50,35706694
 Ângulo zenital (radianos): 0,892899707042705
 Cosseno do Ângulo zenital: 0,770035389885132
 PI: 3,141592654
 dmax: 255
 distância TerraSol: 1,01224254215081
 PI*42: 3,21898567637257

Tabela 2: Ganho do Sensor ETM+

Banda	Gain
1	alto
2	alto
3	alto
4	baixo
5	alto
7	alto

Tabela 4: Parâmetros do sensor, inst e Banda

Banda	Espalhamento	Offset
1		
2		
3		
4	-2,7	245
5	-2,5	270
7		1044

Tabela 3: Parâmetros dos sensores TM e ETM+ (watts/(m²*esterradiano*nm))

Banda	TM/Landsat 5 (a)		ETM+ Landsat 7(b)							
	LMIN	LMAX	Antes de 01/07/2000		Após 01/07/2000					
			Baixo Ganho	Alto Ganho	Baixo Ganho	Alto Ganho				
1	-1,5	185	-6,2	297,5	-6,2	194,3	-6,2	293,7	-6,2	191,6
2	-3,1	342	-6	303,4	-6	202,4	-6,4	300,9	-6,4	196,5
3	-2,7	245	-4,5	235,5	-4,5	158,6	-5	234,4	-5	152,9
4	-2,5	270	-4,5	235	-4,5	157,5	-5,1	241,1	-5,1	157,4
5	-0,45	36	-1	47,7	-1	31,76	-1	47,57	-1	31,06
7	-0,3	19	-0,35	16,6	-0,35	10,932	-0,35	16,54	-0,35	10,8
8	-	-	-5	244	-5	158,4	-4,7	243,1	-4,7	158,3

XML Output:

```

<satellite>
<name>LANDSAT</name>
<number>5</number>
<instrument_channel>1</instrument_channel>
</satellite>
<begin>2007-05-23T12:39:14.013</begin>
<center>2007-05-23T12:39:26.938</center>
<end>2007-05-23T12:39:39.863</end>
</viewing>
<sunIncidenceAngle>
<degree>50</degree>
<minute>21</minute>
<second>25</second>
<millisecond>441</millisecond>
</sunIncidenceAngle>

```

Figura 13 - Parâmetros da imagem informados ao sistema para cálculo da reflectância.

Na Figura 14, é possível observar que no ND 41, houve um crescimento de 500% em relação ao ND 42, caracterizando uma situação atmosférica muito limpa. O método sugere que houve aí a ocorrência de um objeto escuro e utiliza esse valor para estimar a situação atmosférica e o modelo de espalhamento a ser

utilizado. Conforme sugerido por Chavez (1988), deve considerar, entretanto, que o método é baseado apenas em níveis digitais e assim pode ser tratado com certa flexibilidade para definir o modelo de atmosfera adequado, principalmente quando apresentar valores de ND inicial muito próximos aos limites definidos anteriormente na Tabela 3.

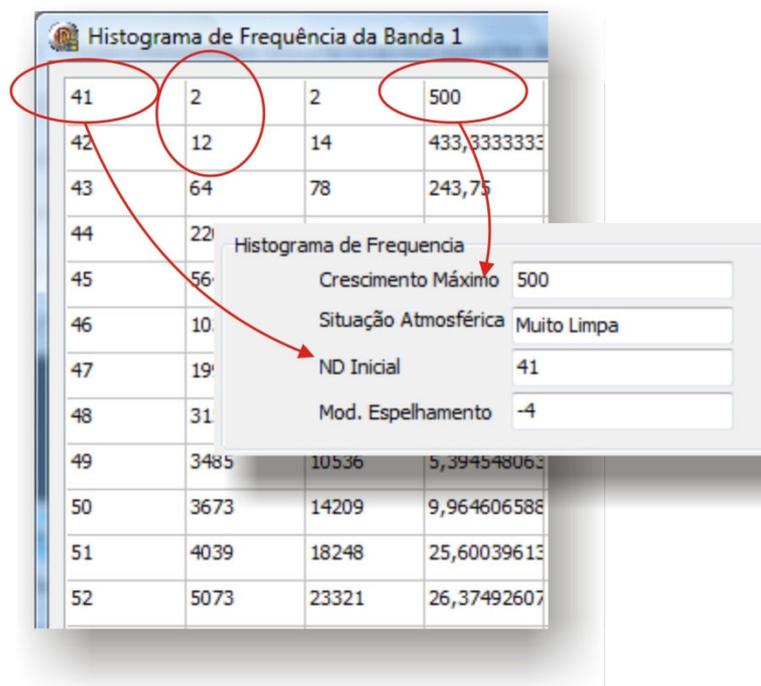


Figura 14 - Recorte do Histograma de Frequência da Banda 1 da imagem de 23/05/2007.

Para o cálculo do espalhamento, são realizados inicialmente os cálculos do ganho nas bandas 1 e 2 e do *offsets*, conforme apresentado nas equações 1 a 3:

Equação 1: Cálculo do ganho₁:

$$\begin{aligned} \text{ganho}_1 &= ND_{\max} / (L^{\max}_1 - L^{\min}_1) \\ \text{ganho}_1 &= 255 / (185 - (-1,5)) \\ \text{ganho}_1 &= 1,367292 \end{aligned}$$

Equação 2: Cálculo do ganho₂:

$$\begin{aligned} \text{ganho}_2 &= ND_{\max} / (L^{\max}_2 - L^{\min}_2) \\ \text{ganho}_2 &= 255 / (342 - (-3,1)) \\ \text{ganho}_2 &= 0,738916 \end{aligned}$$

Equação 3: Cálculo do *offset*:

$$\begin{aligned} \text{offset} &= -(ND_{\max} / (L^{\max}_2 - L^{\min}_2)) * L^{\min}_2 \\ \text{offset} &= -(255 / (342 - (-3,1))) * (-3,1) \\ \text{offset} &= 2,29064 \end{aligned}$$

Os valores de L_{min} e L_{max} são parâmetros dos sensores TM e ETM+ e estão apresentados na Figura 15.

Tabela 3: Parâmetros dos sensores TM e ETM+ (watts/(m²*esterradiano*mm))

Banda	TM Landsat 5 (a)		ETM+ Landsat 7(b)							
	LMIN	LMAX	Antes de 01/07/2000				Após 01/07/2000			
			Baixo Ganho		Alto Ganho		Baixo Ganho		Alto Ganho	
			LMIN	LMAX	LMIN	LMAX	LMIN	LMAX	LMIN	LMAX
1	-1,5	185	-6,2	297,5	-6,2	194,3	-6,2	293,7	-6,2	191,6
2	-3,1	342	-6	303,4	-6	202,4	-6,4	300,9	-6,4	196,5
3	-2,7	245	-4,5	235,5	-4,5	158,6	-5	234,4	-5	152,9
4	-2,5	270	-4,5	235	-4,5	157,5	-5,1	241,1	-5,1	157,4
5	-0,45	36	-1	47,7	-1	31,76	-1	47,57	-1	31,06
7	-0,3	19	-0,35	16,6	-0,35	10,932	-0,35	16,54	-0,35	10,8
8	-	-	-5	244	-5	158,4	-4,7	243,1	-4,7	158,3

Figura 15 - Parâmetros dos sensores TM e ETM+.

Dessa forma, é possível que se estabeleça o ganho normalizado para a banda, conforme equação 4:

Equação 4: Cálculo de ganho_normalizado:

$$\begin{aligned} \text{ganho_normalizado} &= \text{ganho}_2 / \text{ganho}_1 \\ \text{ganho_normalizado} &= 0,738916 / 1,367292 \\ \text{ganho_normalizado} &= 0,540423066 \end{aligned}$$

Com a situação atmosférica considerada muito limpa, o modelo de espelhamento é λ^{-4} , permitindo o cálculo do Fator λ , conforme equação 5:

Equação 5: Cálculo do Fator λ :

$$\begin{aligned} \text{Fator } \lambda &= \lambda_2^{-4} / \lambda_1^{-4} \\ \text{Fator } \lambda &= 0,56^{-4} / 0,485^{-4} \\ \text{Fator } \lambda &= 0,56262 \end{aligned}$$

Com base nos valores acima calculados, preenche-se a tabela ilustrada na Figura 16 e faz-se o cálculo do espalhamento e do espalhamento relativo, conforme equações 6 e 7, respectivamente:

Equação 6: Cálculo do espalhamento

$$\begin{aligned} \text{espalhamento} &= (PE - ND - \text{offset}_1) * \text{Fator } \lambda \\ \text{espalhamento} &= (41 - 8,491402074 - 2,050938) * 0,56262 \\ \text{espalhamento} &= 17,13623 \end{aligned}$$

Equação 7: Cálculo de nd(esp), correspondente ao espalhamento + offset:

$$\begin{aligned} \text{espalhamento+offset} &= (\text{ganho_normalizado} * \text{espalhamento}) + \text{offset} \\ \text{espalhamento+offset} &= (0,540423 * 17,13623) + 2,29064 \end{aligned}$$

$$\begin{aligned} \text{espalhamento+offset} &= (0,540423 * 17,13623) + 2,29064 \\ \text{espalhamento+offset} &= 11,55145283 \\ \text{espalhamento+offset}_{\text{arredondado}} &= 12 \end{aligned}$$

Banda	Ganho	Offset	l	l	% espalhame	Fator l	Ganho norma
1	1,367292225	2,05093833	0,485	18,07311635	50,49041515	1	1
2	0,738916256	2,29064039	0,56	10,16828925	28,40689644	0,562619585	0,540423065
3	1,029471134	2,77957206	0,66	5,27016555	14,72313024	0,291602475	0,752926927
4	0,935779816	2,33944954	0,83	2,107112046	5,886586452	0,116588196	0,684403665
5	6,995884773	3,14814814	1,65	0,134916238	0,376912134	0,007465023	5,116598075
7	13,21243523	3,96373056	2,215	0,04154369	0,116059574	0,002298645	9,663212435

Figura 16 - Comprimento de onda médio de cada banda da imagem.

Depois de calculados, esses valores atualizam a tabela de espalhamento+offset apresentado na Figura 17:

Banda	Espalhamento	Espalh. +offset
1	30,45793300	33
2	17,13622964	12
3	8,88160878	9
4	3,55103548	5
5	0,22736918	4
7	0,07001199	5

Figura 17 - Espalhamento + offset.

As equações 8, 9, 10 e 11 abaixo, calculam respectivamente os parâmetros d^2 , i , j e $ND_{(1\%reflect)}$, necessários para o cálculo de espalhamento acima:

Equação 8: Cálculo de d^2 :

$$\begin{aligned} d &= 1 - (0,01674 * \cos(\pi/180 * 0,9856 * (\text{dia_do_ano} - 4))) \\ d &= 1 - (0,01674 * \cos(2,39107315)) \\ d &= 1,012242542 \\ d^2 &= 1,024634964 \end{aligned}$$

Equação 9: Cálculo do i_2 :

$$\begin{aligned} i_2 &= ((\pi * d^2) * L^{\min}_2) / (E_{\text{sun}} * \cos(\text{zen})) \\ i_2 &= -0,00704291147704971 \end{aligned}$$

Equação 10: Cálculo de j_2 :

$$\begin{aligned} j_2 &= ((\pi * d^2) * ((L^{\max}_2 - L^{\min}_2) / d^{\max}_2)) / E_{\text{sun}} * \cos(\text{zen}) \\ j_2 &= ((3,141592654 * 1,012243^2) * (342 - (-3,1)) / 255) / (1840 * 0,77003539) \\ j_2 &= (3,2189857 * 1,3533333) / 1416,8651176 \\ j_2 &= 4,3563606 / 1416,8651176 \\ j_2 &= 0,0030746 \end{aligned}$$

O valor de E_{sum} corresponde à irradiância da banda e é extraído da tabela ilustrada na Figura 18.

Bandas	E(watts/m2*)
1	1969
2	1840
3	1551
4	1044
5	225,7
7	82,07

Figura 18 - parâmetro do sensor correspondente à irradiância da banda.

Equação 11: Cálculo do $ND_{(1\%reflect)}$:

$$\begin{aligned}
 ND_{(1\%reflect)} &= (0,01-i_1)/j_1 \\
 ND_{(1\%reflect)} &= (0,01-(-0,0031846))/0,0015527 \\
 ND_{(1\%reflect)} &= 8,491402074
 \end{aligned}$$

Com base nos valores anteriormente calculados, a tabela ilustrada na Figura 19 é preenchida e o valor da reflectância do pixel é estabelecido pela equação 12.

bandas	i	j	REFL(max)	REFL(max) corrigida	Mult	ND(0,01 de reflectância)
1	-0,00318459	0,00155274	0,392766438	0,344710309963105	644,0190315	8,4911286536573
2	-0,00704291	0,003074647	0,776992165	0,747139312373827	325,2405488	5,54304588226912
3	-0,00727713	0,002618076	0,660332458	0,644046900276752	381,9597608	6,59916967138793
4	-0,01001031	0,004278920	1,081114331	1,06973004821914	233,7038212	4,67648775402036
5	-0,00833468	0,002647488	0,666774988	0,664519720212467	377,7164053	6,92531220160541
7	-0,01528076	0,003855147	0,967781965	0,963786997118245	259,3934144	6,55766471460368

Figura 19 - Tabela i, j e multi com parâmetros para o cálculo de reflectância.

Equação 12: Cálculo da reflectância:

$$\begin{aligned}
 \text{reflectância} &= j_2 * (ND-nd(esp)) \\
 \text{reflectância} &= 0,003074647 * (13-12) \\
 \text{reflectância} &= 0,003074647
 \end{aligned}$$

O cálculo acima é realizado para cada valor de ND de cada banda para cada imagem analisada, conforme o recorte da tabela apresentado na Figura 20:

11	0	0	0	-0,03416048	-0,00307464	0,00523615	0,02567352	0,01853242	0,02313088
12	0	0	0	-0,03260773	0	0,00785423	0,02995244	0,02117991	0,02698603
13	0	0	0	-0,03105498	0,00307464	0,01047230	0,03423136	0,02382740	0,03084118
14	0	0	0	-0,02950223	0,00614929	0,01309038	0,03851028	0,02647488	0,03469633
15	0	0	0	-0,02794948	0,00922394	0,01570846	0,04278920	0,02912237	0,03855147
16	0	0	0	-0,02639673	0,01229858	0,01832653	0,04706812	0,03176986	0,04240662

Figura 20 - Recorte da tabela de valores de reflectância calculados.

4.2. Rede Neural Artificial

A RNA com uma camada intermediária composta por seis neurônios foi a que apresentou melhor resultado e está em consonância com a sugestão de Silva e Oliveira (2002): “Pode-se definir o número de neurônios na camada escondida como sendo a média aritmética ou ainda como sendo a média geométrica entre tamanho da entrada e da saída da rede”. Dessa forma, a arquitetura que apresentou a melhor convergência é composta por 7 neurônios na camada de entrada, 6 neurônios na camada intermediária e 5 neurônios na camada de saída, conforme ilustrado na Figura 21.

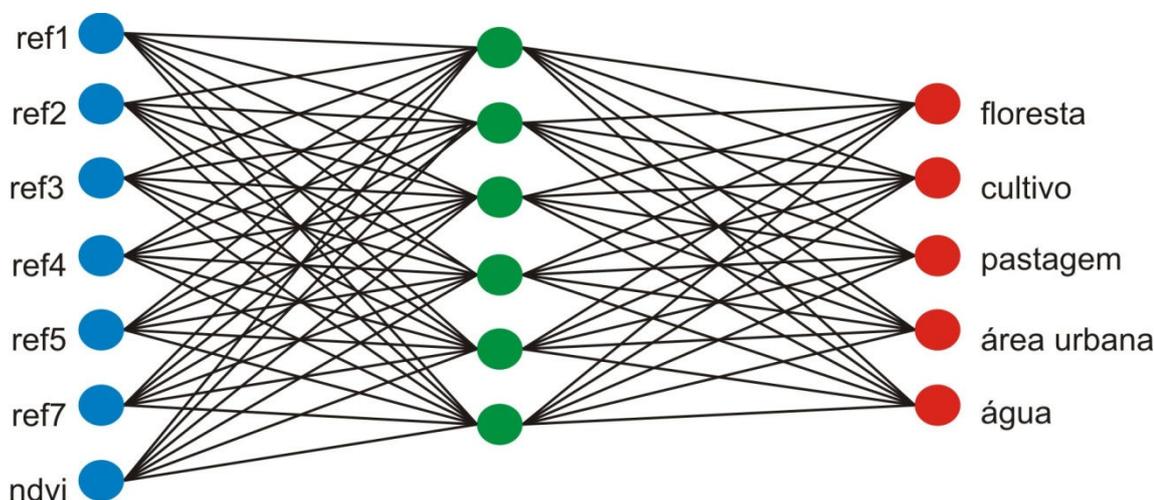


Figura 21 - Esquema da arquitetura da RNA utilizada com 7 neurônios na camada de entrada, 6 na camada intermediária e 5 na camada de saída.

Outros parâmetros também foram ajustados para que a RNA atingisse o resultado satisfatório, conforme pode ser observado na tela de entrada de dados dos parâmetros, apresentado na Figura 22. O número de épocas com melhor resultado foi 7000 e as taxas de inércia e aprendizagem foram respectivamente 90% e 40%.

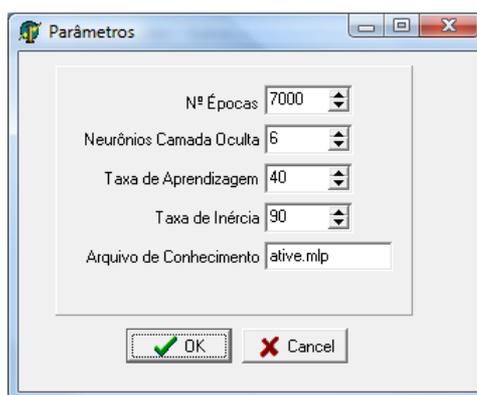


Figura 22 - Parâmetros de configuração da RNA.

O conteúdo atribuído ao campo arquivo de conhecimento define o arquivo onde são armazenados os pesos sinápticos calculados na fase de treinamento da rede. A Figura 23 apresenta um recorte do arquivo ative.mlp utilizado para a classificação das imagens.

SEQ.	ENTRADA	SAÍDA	NÍVEL	PESO
1	1	1	1	-8,69912
2	1	2	1	20,89178
3	1	3	1	157,4361
4	1	4	1	12,16855
5	1	5	1	-91,3696
6	1	6	1	191,0669
7	2	1	1	41,90349
8	2	2	1	20,85539
9	2	3	1	211,3932
10	2	4	1	109,9738
11	2	5	1	-118,695
12	2	6	1	102,4765
13	3	1	1	8,229657
14	3	2	1	48,61262
15	3	3	1	289,5334
16	3	4	1	-31,8541
17	3	5	1	-177,748
18	3	6	1	-35,8084
19	4	1	1	-37,1599
20	4	2	1	73,87357
...
70	6	3	2	3,313698
71	6	4	2	-132,585
72	6	5	2	-0,07467

Figura 23 - Recorde do arquivo de conhecimento com pesos sinápticos de cada conexão entre os neurônios da RNA.

Após estabelecer os parâmetros iniciais e realizar o treinamento, a RNA foi testada. Ao final da etapa de teste da rede neural, foi montada a matriz de confusão e, com base em seus valores, foi calculado o índice Kappa. Conforme apresentado na Figura 24, o índice de acurácia Kappa dos dados classificados pela RNA foi de 85,8%, acima dos 80% considerados bom, segundo Congalton e Green (2008).

	Área Urbana	Floresta	Culturas	Solo Exposto	Água	TOTAL
Área Urbana	228	0	3	27	6	264
Floresta	0	259	11	0	7	277
Culturas	0	51	211	0	4	266
Solo Exposto	48	0	0	254	0	302
Água	0	0	0	0	275	275
TOTAL	276	310	225	281	292	1384

Estatística Kappa **Alta Concordância**

P(O) = 1227
P(e) = 277,270
K = 0,858

testar todos os dados

Figura 24 - Matriz de Confusão e Índice Kappa resultante do teste da rede neural.

Com os valores dos pesos sinápticos satisfatoriamente estabelecidos, os recortes das imagens foram submetidos ao algoritmo de classificação e o resultado pode ser observado na Figura 25. À esquerda, encontra-se uma composição colorida da imagem de entrada do dia 09/05/2008 e à direita, a imagem resultado da classificação.

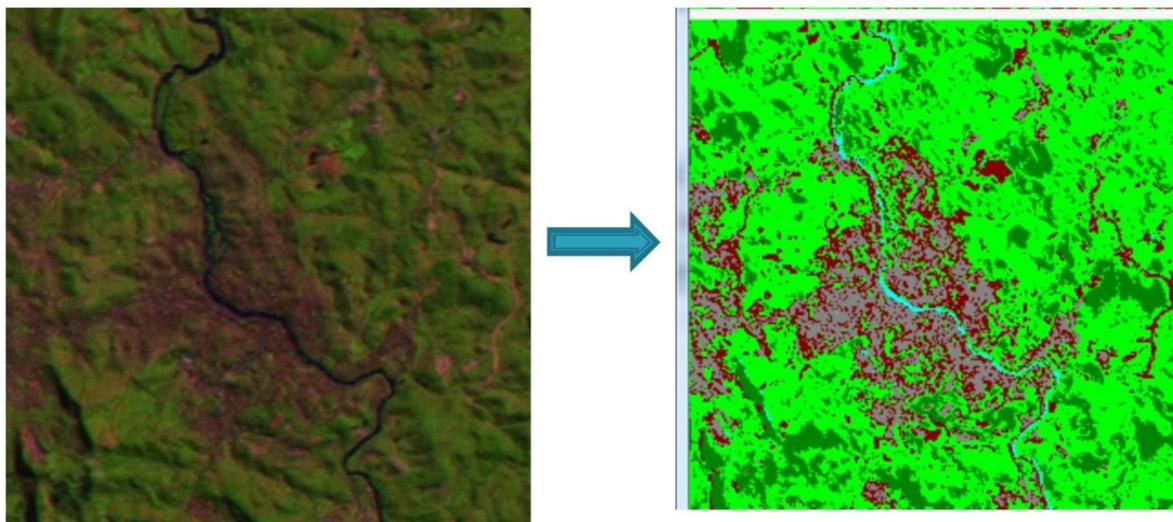


Figura 25 - Classificação da imagem pelo software Ative.

O mesmo processo é repetido para as diversas imagens que se deseja comparar e a classificação de cada ponto é armazenada no banco de dados para gerar os resultados, que podem ser apresentados em forma de imagem, tabela e gráfico. A Figura 26 apresenta as imagens geradas respectivamente para as datas 09/05/2008, 12/05/2009, 15/05/2010 e 18/05/2011, para que o resultado possa ser visualmente analisado.

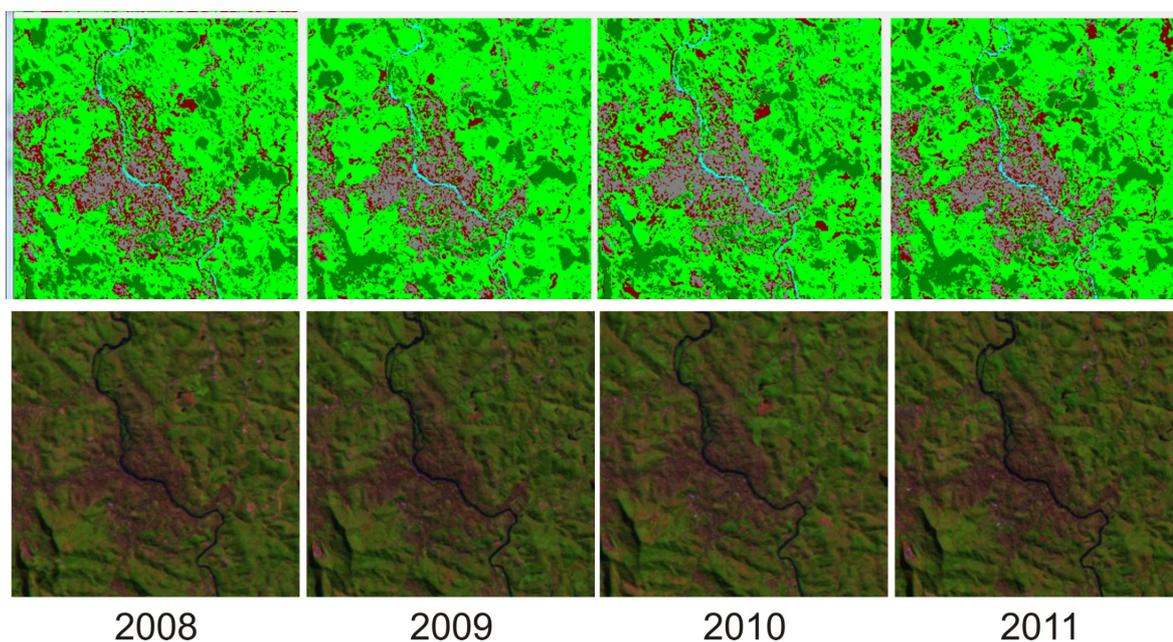


Figura 26 - Classificação da imagem ano a ano

A Figura 27 apresenta a saída do sistema em formato de tabela e gráfico de uso e ocupação do solo.

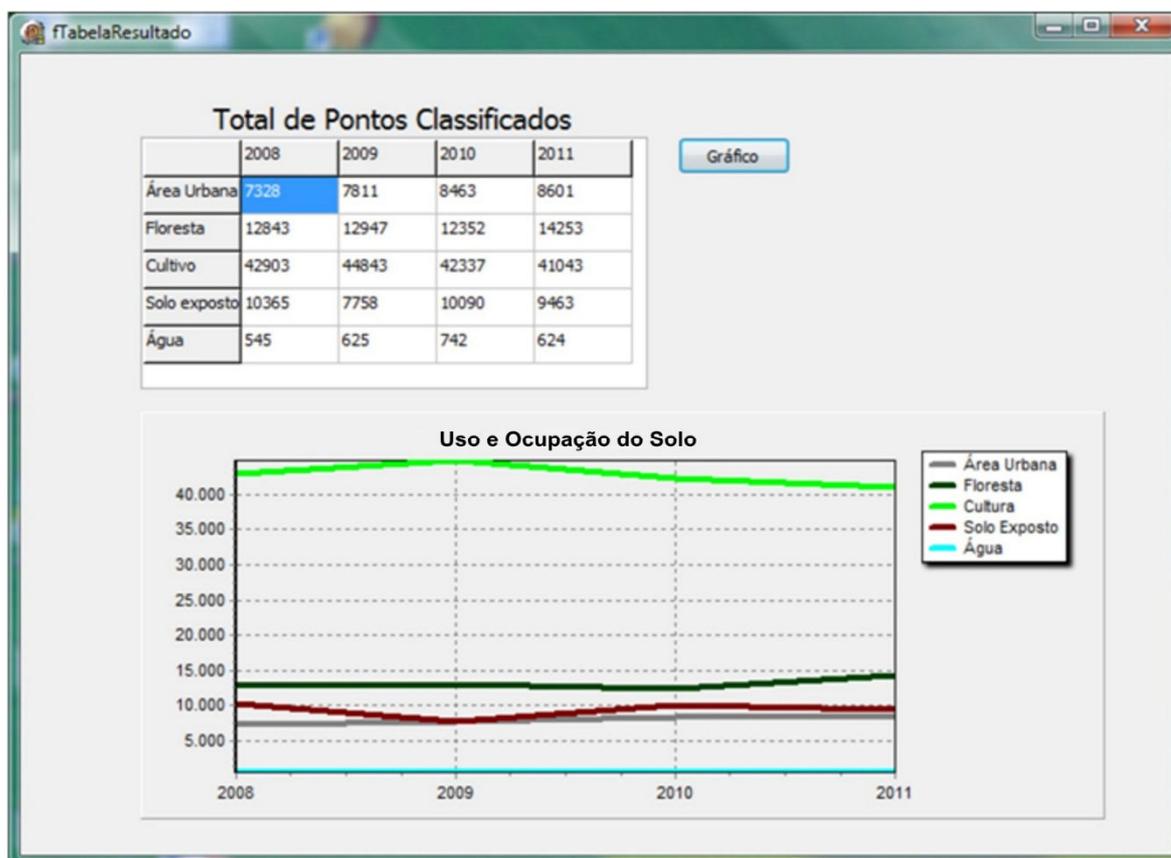


Figura 27 - Tela de saída do sistema Ative com a tabela do total de pontos classificados e o gráfico de uso e ocupação do solo.

5. CONCLUSÃO

O presente trabalho apresentou uma forma automatizada para a correção atmosférica e cálculos da reflectância utilizando o modelo DOS, proposto por Chavez (1988) e do índice de vegetação NDVI, desenvolvida como parte integrante do software Ative, que tem como objetivo a análise temporal de uso e ocupação do solo através de imagens do satélite Landsat. A metodologia apresentada servirá, não apenas para o software Ative, mas também como componente para outras ferramentas computacionais.

Conforme exemplificado, a inferência direta da correção atmosférica a partir do número digital representa uma simplificação da realidade, porém, essa mesma simplificação pode viabilizar o processo, já que métodos mais complexos requerem dados de entrada que, muitas vezes, os usuários não possuem. Dessa forma, com a presente ferramenta, não serão exigidos profundos conhecimentos dos conceitos de sensoriamento remoto, o que fará com que seja um instrumento valioso para apoiar e ampliar a capacidade de pesquisadores, órgãos governamentais e não governamentais (ONGs) e instituições acadêmicas que se dedicam ao estudo de mudanças climáticas e ecossistemas dinâmicos para que possam mapear e monitorar as paisagens utilizando imagens obtidas de satélite.

Os resultados alcançados neste estudo apresentaram um desempenho satisfatório da RNA na classificação do uso e cobertura do solo e imagens, viabilizando assim a utilização do modelo desenvolvido em trabalhos futuros. O modelo desenvolvido, baseado em RNA, classificou satisfatoriamente os dados testados. A exatidão foi alcançada após teste de configuração da arquitetura da rede e sucessivos treinamentos do modelo.

O resultado final foi validado utilizando matriz de confusão e índice Kappa, apresentando acurácia de 85,8%, considerado satisfatório na literatura.

O resultado apresentado em forma de imagens, tabelas e gráficos está em consonância com a tendência da engenharia de cognição e semiótica dos sistemas modernos, tornando seu entendimento claro e intuitivo.

REFERÊNCIAS BIBLIOGRÁFICAS

- Almeida, C. M., Gleriani, J. M., Castejon, E. F., Soares-Filho, B. S. (2008) Using neural networks and cellular automata for modelling intra-urban land-use dynamics. *International Journal of Geographical Information Science [S.l.]*, v. 22, n. 9, p. 943-963.
- Angelo, N. P. (2000) *Aplicação de Filtros de Gabor no Processo de Classificação de Imagens Digitais com Base em Atributos de Textura*. Tese de Doutorado. Centro Estadual de Pesquisas em Sensoriamento remoto e Meteorologia - CEP SRM - Curso de Pós-Graduação em Sensoriamento Remoto, Universidade Federal do Rio Grande do Sul, Porto Alegre. 168p.
- Atlântica, F. S. M. (2009) *Atlas dos Remanescentes Florestais da Mata Atlântica. Período 2005-2008*. Relatório Técnico. Fundação SOS Mata Atlântica e Instituto Nacional de Pesquisas Espaciais. São Paulo, 156p.
- Barreto Luiz, A. J., Gürtler, S., Gleriani, J. M., Epiphanyo, J.C.N., Campos, R.C. (2003). Reflectância a Partir do Número Digital de Imagens ETM+. *Anais XI SBSR*. pp. 2071-2078.
- Beluco, A. (2002) *Classificação de Imagens de Sensoriamento Remoto Baseada em Textura por Redes Neurais*. Tese de Doutorado. Centro Estadual de Pesquisas em Sensoriamento remoto e Meteorologia - CEP SRM - Curso de Pós-Graduação em Sensoriamento Remoto, Universidade Federal do Rio Grande do Sul, Porto Alegre, 154p.
- Câmara, G.; Souza, R.C.M; Freitas, U.M.; Garrido, J.; Mitsuo, F. (1996) Spring: Integrating Remote Sensing and GIS by Object-Oriented Data Modelling. *Computers & Graphics*, v. 20, p.395-403.
- Carvalho, A. P. D. L. F. D. (2009) *Redes Neurais Artificiais*. São Paulo: Universidade de São Paulo.

- Cgis, T. U. (2010) *Normalized difference Vegetation Index (NDVI)*. CGIS, Towson University. Disponível em http://chesapeake.towson.edu/data/all_ndvi.asp. Acesso em 10/05/2010.
- Chagas, C.S. (2006) *Mapeamento Digital de Solos por Correlação Ambiental e redes Neurais em uma Bacia Hidrográfica no Domínio de Mar dos Morros*. Tese de Doutorado. Universidade Federal de Viçosa, Viçosa, MG. 238p.
- Chavez, S. Jr. P. (1988) An improved dark-object subtraction technique for atmospheric scattering correction of multispectral data. *Remote Sensing of Environment*. Flagstaff, Arizona, EUA, Vol. 24, pp. 459-479.
- Chen, F. (2008) Mapping Soil Organic Carbon Concentration for Multiple Fields with Image Similarity Analysis. *Soil Science Society of America journal*. [S.l.], v. 72, n. 1, p. 186-193.
- Congalton, R G. e Green, K. (2008). *Assessing the Accuracy of Remotely sensed Data: principles and practices*. 2nd Ed. New York: CRC Press. 210p.
- Eoportal.Org. (2009) *EASI/PACE Version 6.0*. Disponível em <https://directory.eoportal.org/web/guest/home;jsessionid=B0B4279C96E3D3F647ED5196922C1654.eodisp-prod5040>. Acesso em 12/07/2010.
- Erdas, Inc. (2010) *Erdas Imagine: The World Uses ERDAS IMAGINE to Create Information from Imagery*. Atlanta, Georgia, EUA: Disponível em <http://geospatial.intergraph.com/products/ERDASIMAGINE/ERDASIMAGINE/Details.aspx>. Acesso: 12/07/2010.
- Esa (2012). Disponível em earth.esa.int/0xc1cce41c_0x0000069c. Acesso em: 10/07/2012.
- Esri. (2009) *ArcGIS: A Complete Integrated System*. São José dos Campos, SP. Disponível em <http://www.esri.com/software/arcgis>. Acesso: 09/07/2010.
- Fas, F. O. A. S. (2010) *Electromagnetic Spectrum: Spectral Signatures*. Washington, DC: Federation of American Scientists. Disponível em http://www.fas.org/irp/imint/docs/rst/Intro/Part2_5.html. Acesso em 24/05/2010.
- Figueiredo, D. (2005). *Conceitos Básicos de Sensoriamento Remoto*. Relatório Técnico. CONAB – Companhia nacional de Abastecimento. Brasília. 32p.
- Florenzano, T. G. *Imagens de Satélite para Estudos Ambientais*. São Paulo: Oficina de Textos, 2002.
- Galo, M.L.B.T., Velini, E.D., Trindade, M.L.B., & Santos, S.C.A.. (2002). Uso do sensoriamento remoto orbital no monitoramento da dispersão de macrófitas nos reservatórios do complexo Tietê. *Planta Daninha*, 20(spe), 7-20. Disponível em http://www.scielo.br/scielo.php?script=sci_arttext&pid=S0100-83582002000400002&lng=en&tling=pt. Acesso 11/07/2012.

- Guahyba, A. *Visão Geral sobre Redes Neurais*. Disponível em <http://www.guahyba.vet.br/avicultura/neurais.htm>. Acessado em 13/08/2011.
- Gürtler, S.; Epiphanyo, J.C.N; Luiz, A.J.B.; Formaggio, A.R. (2005). Planilha Eletrônica para Cálculo da Reflectância em Imagens TM e ETM+ Landsat. *RBC - Revista Brasileira de Cartografia*. ISSN 1808-0936, Vol. 57/02.
- Hashimoto, R. F. (2010) *Visão e Processamento de Imagens*. São Paulo: Universidade Federal de São Paulo – USP. Disponível em <http://www.vision.ime.usp.br/>. Acesso em 24/05/2010.
- Huete, A. R., Liu, H.Q, Batchily, K., Van Leeuwen W. (1997). A comparison of vegetation indices over a global set of TM images for EOS-MODIS. *Remote Sensing of Environment*, Vol. 59, Issue 3, p.440-451.
- Idesam. (2010) *Claslite: User friendly Forest Monitoring Technology*. Stanford, CA, EUA. Disponível em <http://claslite.stanford.edu/en/index.html>. Acesso em 13/07/2010.
- Jayas, D. S., Paliwal, J., Visen, N. S. (2000) Multi-layer neural networks for image analysis of agricultural products. *Journal of agricultural engineering research* [S.I.], v. 77, n. 2, p. 119-128.
- Justice, C. O., Vermote, E. Townshend, J.R.G., Defries, D.P.R, Hall, D.K., Salomonson, V. V., Privette, J.L., Riggs, G., Strahler, A., Lucht, W., Myneni, R.B., Knyazikhin, Y. Running, S.W., Nemani, R.R., Wan, Z., Huete, A.R., Leeuwen, W.V., wolfe, R.E., Giglio, L., Muller, J.P., Lewis, P., Barnsley, M.J. (1998) The moderate resolution imaging spectroradiometer (MODIS): Land remote sensing for global change. *IEEE Transactions on Geoscience & Remote Sensing*. Vol. 36, Issue 4, p. 36.
- Latorre, M., Carvalho Júnior, O.A., Carvalho, A.P.F., Shimabukuro, Y.E. (2002). Correção Atmosférica: Conceitos e Fundamentos. *Espaço e Geografia*. V5.
- Lopes, E. S. S. (2003) *Procedimentos Geoestatísticos com o Spring - Inpe*. Relatório Técnico. Disponível em: <<http://www.rc.unesp.br/igce/aplicada/public.html>>. Acesso em: 06/07/2010. 59p.
- Luo, L.; Mountrakis, G. (2010) Integrating intermediate inputs from partially classified images within a hybrid classification framework: An impervious surface estimation example. *Remote Sensing of Environment* [S.I.], v. 114, n. 6, p. 1220-1229.
- Mendonza R., Hoover, E. (2005). *Síntese Genética de redes Neurais Artificiais ART2 na Classificação de Imagens Aster para Mapeamento de Uso e cobertura da Terra na Região Norte do Mato Grosso*. Dissertação de Mestrado. São José dos Campos. INPE-12256-TDI/981.
- Millard, P., Wright, G. G., Adams, M. J., Birnie, R. V., Whitworth, P. (1990) Estimation of light interception and biomass of the potato (*Solanum tuberosum*

L.) from reflection in the red and near-infrared spectral bands. *Agricultural and Forest Meteorology* [S.I.], v. 53, n. 1-2, p. 19-31.

Morain, S. A. (1998) A Brief History of Remote Sensing Applications, with emphasis on Landsat. In: PRESS, N. A. (Ed.). *People and Pixels: Linking Remote Sensing and Social Science*. Washington, DC: National Academic Press, Cap.2.

Moreira, M. A. (2005) *Fundamentos do Sensoriamento Remoto e Metodologias de Aplicação*. 3ª. ed. Viçosa, MG: Editora UFV.

Nasa, N. A. A. S. A. (2010) *Landsat Then and Now*. In: ROCCHIO, L. (Ed.). About Landsat. Washington: NASA.

Nasa (2012). Disponível em http://ltpwww.gsfc.nasa.gov/IAS/handbook/handbook_htmls/chapter11/chapter11.html. Acesso em 10/07/2012.

Padilha, P. C. C. (2001) *Desenvolvimento de uma Metodologia de Sintonia de Controladores "Fuzzy" Utilizando redes Neurais. Aplicações em Processos Petroquímicos*. Tese de Mestrado - Engenharia Elétrica, Instituto Militar do Exército - IME, Rio de Janeiro, 95p.

Ponzoni, F. J. (2002) *Sensoriamento Remoto no Estudo da Vegetação: Diagnosticando a Mata Atlântica*. Relatório Técnico. INPE - Instituto Nacional de pesquisas Espaciais. São José dos Campos, p.28.

Pradhan, B.; Lee, S. (2010) Regional landslide susceptibility analysis using back-propagation neural network model at Cameron Highland, Malaysia. *Landslides* [S.I.], v. 7, n. 1, p. 13-30.

Ribeiro, L.N. (2003) *Rede Neural com Retroprogramação: uma aplicação na classificação de imagens de satélite*. Dissertação de Mestrado. Campo Grande, MS: Universidade Federal de Mato Grosso do Sul, 131p.

Rosendo, J. S. (2005). *Índices de Vegetação e Monitoramento do Uso do Solo e Cobertura Vegetal na Bacia do Rio Araguari - MG - Utilizando Dados do Sensor Modis*. Tese de Doutorado. Universidade Federal de Uberlândia. [Online].

Santos, A.R., Peluzio, T.M.O. e Saito, N.S. (2011) *SPRING 5.1.2 Passo a passo: Aplicações práticas*. Alegre: CCAUFES 155 p.

Serafini Júnior, S. (2008) O uso do SPRING como ferramenta de diagnóstico ambiental dos aspectos de uso do solo: estudo de caso de um empreendimento imobiliário para ser implantado no município de Itatiba/SP. *Instituto Navegar*. Itatiba, SP. p.14.

Silva, E., Oliveira, A.C., (2002) *Dicas para a Configuração da Rede Neural*. NCE, UFRJ. Rio de Janeiro. Disponível em http://equipe.nce.ufrj.br/thome/grad/nn/mat_didatico/dicas_configuracao_rna.pdf. Acessado em 07/08/2011.

- Silva, P. G. (2004) *Detecção de Mudanças em Áreas de Florestas Tropicais sob Exploração Madeireira Através da Técnica Análise do Vetor Mudança*. 2004. 122 f. Dissertação de Mestrado. INPE, São José dos Campos.
- Silva, H. R., Altimare, A.L., Lima, E.C.F. (2006). Sensoriamento remoto na identificação do uso e ocupação da terra na área do projeto "Conquista da Água" Ilha Solteira - SP, Brasil, *Engenharia Agrícola*, pp. 328-334.
- Simon, H. A. (1965) *Comportamento administrativo: estudo dos processos decisórios nas organizações administrativas*. 2ª. ed. Rio de Janeiro: Fundação Getulio Vargas.
- Souza, J. D. S. A. D. e Medeiros, J. S. D. (2003) Modelagem de Carta Síntese de Subsidio à Gestão do Território do sul do Amapá, através de Análise Geográfica em Spring. *Boletim do Museu Paraense Emílio Goeldi*, v. 1, Issue 1, p 137-140.
- Sugawara, M. T. (2008) *Sistema Automatizado para Estimação da Evapotranspiração de Referência e do Balanço Hídrico para Região Norte Fluminense Utilizando Redes Neurais Artificiais (RNAs)*. Tese de Doutorado. Centro de Ciências e Tecnologias Agropecuárias, Universidade Estadual Norte Fluminense, Campos dos Goytacazes, 77p.
- Sulsoft. (2009). *IDRISI 16: The Taiga Edition*. Porto Alegre, RS. Disponível em <http://www.idrisi.com.br/>. Acesso: 13/07/2009.
- Sulsoft. (2010) *ENVI EX*. Porto Alegre, RS. Disponível em <http://www.envi.com.br/index.php/modulos/fx>. Acesso: 12/07/2010.
- Tanajura, E.L.X., Antunes, M.A.H., Uberti, M.S. (2005). Avaliação de Índices de Vegetação Para a Discriminação de Alvos Agrícolas em Imagens de Satélites. *Anais XII Simpósio Brasileiro de Sensoriamento Remoto*. 16-21 de abril de 2005, pp. 301-307.
- Tatibana, C. Y.; Kaetsu, D. Y. (2010) *Uma Introdução às Redes Neurais*. Maringá, PR: Universidade Estadual de Maringá-PR. Disponível em <http://www.din.uem.br/ia/neurais/#indice>. Acesso em 24/05/2010.
- Todt, V. (1998) *Avaliação de Desempenho de Classificadores Neurais para Aplicações em Sensoriamento Remoto*. Tese de Doutorado. Centro Estadual de Pesquisas em Sensoriamento remoto e Meteorologia - CEP SRM - Curso de Pós-Graduação em Sensoriamento Remoto, Universidade Federal do rio Grande do Sul, Porto Alegre, 161p.
- Weier, J., Herring, D. (2010) *Measuring Vegetation (NDVI & EVI)*. Disponível em <http://earthobservatory.nasa.gov/Features/MeasuringVegetation/printall.php>. Acesso 10/07/2012.