



**LILIANY APARECIDA DOS ANJOS PEREIRA**

**Classificação automática de áreas cafeeiras em  
imagens de satélite, utilizando Redes Neurais  
Artificiais**

**LAVRAS – MG**

**2013**

**LILIANY APARECIDA DOS ANJOS PEREIRA**

**CLASSIFICAÇÃO AUTOMÁTICA DE ÁREAS CAFFEEIRAS EM  
IMAGENS DE SATÉLITE, UTILIZANDO REDES NEURAI  
S ARTIFICIAIS**

**Monografia apresentada ao  
Colegiado de Curso de Ciência da  
Computação, para obtenção do  
título de Bacharel em Ciência da  
Computação.**

**Orientador**

**Wilian Soares Lacerda**

**Coorientadora**

**Tatiana Grossi Chquiloff Vieira**

**LAVRAS – MG**

**2013**

**LILIANY APARECIDA DOS ANJOS PEREIRA**

**CLASSIFICAÇÃO AUTOMÁTICA DE ÁREAS CAFEEIRAS EM  
IMAGENS DE SATÉLITE, UTILIZANDO REDES NEURAIAS  
ARTIFICIAIS**

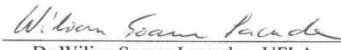
Monografia apresentada ao Colegiado  
de Ciência da Computação para  
obtenção do título de Bacharel em  
Ciência da Computação pela  
Universidade Federal de Lavras.

Aprovada em 08 de abril de 2013.

Dr. Cristiano Leite de Castro – UFLA

M. Sc. Lívia Naiara de Andrade – UFLA

M. Sc. Tatiana Grossi Chquiloff Vieira – EPAMIG

  
Dr. Wilian Soares Lacerda – UFLA  
Orientador

**LAVRAS – MG  
2013**

*Este trabalho é dedicado às pessoas que sempre estiveram ao meu lado me apoiando e principalmente acreditando em mim.*

*Dedico a Deus, pela saúde, fé e oportunidade de lutar por um futuro melhor.*

*Aos meus pais e minhas irmãs, que me deram educação, amor, carinho e exemplo de vida sem os quais eu não teria chegado a lugar algum e que em todos os momentos difíceis da minha vida têm intercedido junto a DEUS, pelo meu sucesso e felicidade. Vocês me deram tudo e vão estar eternamente em tudo o que eu fizer.*

*À Amália, amiga inseparável, pela paciência nas horas a fio em que fiquei na frente do computador e principalmente pelo compartilhamento do entusiasmo, pela motivação, pelo constante apoio que sempre me dá e nunca medindo esforços para me ajudar.*

*Ao professor, Wilian Soares Lacerda, pela paciência, sabedoria e dedicação com a qual orientou este trabalho, sendo sensível às diversas situações que lhes foram apresentadas, tornando possível a conclusão desta monografia.*

*Enfim, dedico essa conquista a todos que de alguma forma tornaram este caminho mais fácil de ser percorrido com imensa gratidão.*

DEDICO

## AGRADECIMENTOS

Primeiramente a Deus, que a todo o momento me ajudou a ultrapassar os obstáculos e acreditar, iluminando-me para que fosse possível a conclusão deste trabalho.

À Universidade Federal de Lavras e ao Departamento de Ciência da Computação.

Ao meu orientador Wilian Soares Lacerda que dedicou seu tempo me orientando. Obrigada pelos ensinamentos, atenção e dedicação ao longo deste período.

À Professora Lívia Naiara Andrade, pelo conhecimento passado, pela ajuda e apoio que ajudaram bastante no desenvolvimento deste trabalho.

A minha coorientadora Tatiana, uma das idealizadoras deste trabalho, por toda a atenção a mim disponibilizada.

Aos meus pais, Zaira e José Geraldo, e minha irmã Lívia, pelo eterno orgulho, confiança, amor e compreensão, sempre prontos para me ajudar.

À minha irmã Di, meu cunhado Patrick e a minha sobrinha Isabelly, pelo incentivo e pelos bons conselhos.

À Amália pelo apoio, incentivo, pela paciência e compreensão, sempre acreditando em mim.

Ao Laboratório de Geoprocessamento da EPAMIG, o Geosolos, às pesquisadoras Helena Maria Ramos Alves e Margarete Marin Lordelo Volpato pelo apoio, sugestões e ensinamentos prestados.

À FAPEMIG (Fundação de Amparo e Pesquisa do Estado de Minas Gerais), pelos recursos financeiros e bolsas.

Obrigada a todos que participaram desta minha etapa, me fazendo crescer, tanto pessoalmente como profissionalmente.

## RESUMO

A classificação digital de imagens de satélite tem ganhado, nas últimas décadas, reconhecimento como técnica para suprir a escassez dos mapeamentos temáticos. Para classificar dados de diferentes origens as Redes Neurais Artificiais (RNA) são atualmente uma opção emergente. Minas Gerais é o estado que se destaca entre os demais estados brasileiros em área plantada e quantidade produzida de café. O conhecimento do ambiente em que o café está inserido permite um melhor planejamento da produção, visando o desenvolvimento sustentável e a obtenção de produtos com qualidade, uma vez que os fatores ambientais exercem grande influência sobre a qualidade da bebida. Assim o objetivo deste trabalho foi a criação de um algoritmo usando o software MATLAB e toolbox de Redes Neurais deste para a classificação de áreas cafeeiras em imagens de satélite, para identificar e mapear o uso e ocupação da terra, com ênfase na identificação de áreas cafeeiras na região de Três Pontas localizada no sul de Minas Gerais. Foram utilizadas RNAs convolutivas que é um Perceptron de múltiplas camadas projetado especificamente para reconhecer formas bidimensionais. Foi utilizado também o algoritmo backpropagation para o treinamento da rede neural. Para o desenvolvimento deste trabalho foram necessárias as seguintes etapas: definição do problema; pré-processamento dos dados; coleta dos dados de treinamento e de teste; arquitetura da rede; treinamento; teste e validação. Neste trabalho, foi demonstrado o potencial das redes neurais na classificação automática de áreas cafeeiras em imagens de satélite, o que justifica futuros trabalhos nesta área. O índice de acurácia Kappa obtido na região cafeeira de Três Pontas foi de 0,6711, com um índice global de 79,6025%, as áreas de café tiveram um acerto de 76,25%. Trabalhos Futuros visam a utilização de outros tipos de imagens, advindas de outros satélites e outras regiões, além do acréscimo de outras características como forma, textura, índice de vegetação, etc.

Palavras-chave: Classificação automática. Redes Neurais Artificiais. Imagens de satélite. Cafeicultura.

## ABSTRACT

Digital satellite imagery classification in recent decades has been increasingly recognized as a technique for breaching the shortages of thematic mapping. Artificial Neural Networks (ANN) are currently an emerging option for sorting data from different sources. Minas Gerais state stands out from other Brazilian states in terms of planted area and quantity of coffee produced. As environmental factors have a great influence on the quality of the drink, an understanding of the environment in which the coffee is inserted allows for better production planning, aiming at sustainable development, and the achievement of quality products. Thus, the objective of this work is create an algorithm using the software MATLAB toolbox and Neural Networks for classification of this coffee areas in satellite images, to identify and map the use and occupation of land, with an emphasis on identifying coffee areas Três Pontas of the region located in the south of Minas Gerais. To implement and utilize the MatlabNeural Networks Toolbox software we use convolutional ANN, that is, a multilayer perceptron specifically designed to recognize two-dimensional shapes. We also use the backpropagation algorithm for neural network training. The project will be carried out in various stages: problem definition, pre and post-processing of data, data collection training and testing, network structure design, training, testing and validation. In this study, we demonstrated the potential of neural networks in automatic classification of coffee areas in satellite images, which justifies further work in this area. The Kappa index of accuracy obtained in the coffee region of Três Pontas was 0.6711, with an overall rate of 79.6025%, areas of coffee had a hit of 76.25%. Future work aimed at using other types of images, resulting from other satellites and other regions, besides the addition of other features like shape, texture, vegetation index, etc.

Keywords: Automatic classification. Artificial Neural Networks. Satellite images, Coffee.

## LISTA DE ILUSTRAÇÕES

Figura 2.1	Modelo de um neurônio biológico.....	18
Figura 2.2	Modelo matemático de um neurônio.....	19
Figura 2.3	Rede de múltiplas camadas.....	20
Figura 2.4	Exemplo de rede neural convolutiva.....	23
Figura 2.5	Modelo Graphical User Interface.....	28
Figura 2.6	Representação de uma imagem digital.....	33
Figura 2.7	Resposta espectral da mata e do café.....	37
Figura 3.1	Localização da área de estudo.....	40
Figura 3.2	Imagens TM/Landsat 5.....	41
Figura 3.3	Mapa de Uso e Ocupação da Terra de Três Pontas – MG.....	43
Figura 3.4	Diagrama de blocos da metodologia.....	46
Figura 3.5	Pré-processamento da imagem.....	47
Figura 3.6	Diagrama de blocos da implementação.....	49
Figura 3.7	Exemplo da banda 3 da imagem.....	50
Figura 3.8	Exemplo de uma imagem de Uso da Terra.....	51
Figura 3.9	Divisão da imagem.....	52
Figura 3.10	Janela 3x3 que percorre as matrizes das bandas.....	53
Figura 3.11	Janela 3x3 transformada em vetor.....	53
Figura 3.12	Entrada no formato desejado pela rede.....	54
Figura 3.13	Saída desejada da rede.....	55
Figura 3.14	Validação da classificação.....	58
Figura 4.1	Mapa de referência.....	61
Figura 4.2	Mapa classificado pela RNA, janela = 11x11.....	63
Figura 4.3	Mapa classificado pela RNA, janela = 5x5.....	65
Figura 4.4	Mapa classificado pela RNA, janela = 7x7.....	66
Figura 4.5	Mapa classificado pela RNA, janela = 9x9.....	67



Figura 4.6	Gráfico do erro médio quadrático.....	70
Figura 4.7	Mapa de Três Pontas, classificado pela RNA.....	71

## LISTA DE SIGLAS

APP	Áreas de Proteção Permanente
CONAB	Companhia Nacional de Abastecimento
CONAMA	Conselho Nacional do Meio Ambiente
GUI	Graphical User Interface
IGAM	Instituto Mineiro de Gestão das Águas
INPE	Instituto Nacional de Pesquisas Espaciais
HRV	High Resolution Visible
LEGAL	Linguagem Espacial para Geoprocessamento Algébrico
MATLAB	MATrix LABoratory
MLP	Multi-Layer Perceptron
RNA	Redes Neurais Artificiais
SIG	Sistemas de Informação Geográfica
SPRING	Sistema de Processamento de Informações Georreferenciadas
TM	Thematic Mapper

## SUMÁRIO

<b>1 INTRODUÇÃO</b> .....	<b>13</b>
<b>1.2 Objetivos</b> .....	<b>15</b>
<b>1.2.1 Objetivos Específicos</b> .....	<b>15</b>
<b>1.3 Organização da monografia</b> .....	<b>16</b>
<b>2 REVISÃO BIBLIOGRÁFICA</b> .....	<b>17</b>
<b>2.1 Redes Neurais Artificiais</b> .....	<b>17</b>
<b>2.1.1 O cérebro e o neurônio biológico</b> .....	<b>18</b>
<b>2.1.2 Neurônio artificial</b> .....	<b>19</b>
<b>2.1.2 Arquitetura das Redes Neurais Artificiais</b> .....	<b>21</b>
<b>2.1.1 Multi-Layer Perceptron</b> .....	<b>22</b>
<b>2.1.2 Redes Neurais Artificiais convolutivas</b> .....	<b>23</b>
<b>2.1.3 Aprendizado</b> .....	<b>25</b>
<b>2.1.4 Backpropagation</b> .....	<b>26</b>
<b>2.2 MATLAB</b> .....	<b>27</b>
<b>2.2.1 Toolbox de RNA do MATLAB</b> .....	<b>28</b>
<b>2.3 SPRING</b> .....	<b>30</b>
<b>2.4 Sensoriamento remoto</b> .....	<b>30</b>
<b>2.2.2 Produtos do sensoriamento remoto</b> .....	<b>33</b>
<b>2.2.3 Bandas</b> .....	<b>35</b>
<b>2.3 Classificação de imagens de satélite</b> .....	<b>37</b>
<b>2.3.1 O problema da identificação automática de café</b> .....	<b>38</b>
<b>2.4 Índice Kappa</b> .....	<b>39</b>
<b>3 MATERIAIS E MÉTODOS</b> .....	<b>40</b>
<b>3.1 Materiais</b> .....	<b>40</b>
<b>3.1.1 Área de estudo</b> .....	<b>40</b>

<b>3.1.2</b>	<b>Imagens TM/Landsat 5 .....</b>	<b>41</b>
<b>3.1.3</b>	<b>Ferramentas computacionais utilizadas .....</b>	<b>45</b>
<b>3.2</b>	<b>Métodos.....</b>	<b>47</b>
<b>3.2.1</b>	<b>Pré-processamento da imagem.....</b>	<b>48</b>
<b>3.2.2</b>	<b>Procedimento metodológico para desenvolvimento do software.....</b>	<b>49</b>
<b>4</b>	<b>RESULTADOS .....</b>	<b>60</b>
<b>4.1</b>	<b>Definição da arquitetura da RNA .....</b>	<b>60</b>
<b>4.1.1</b>	<b>Camadas escondidas e número de neurônios .....</b>	<b>60</b>
<b>4.1.2</b>	<b>Quantidade de épocas de treinamento .....</b>	<b>61</b>
<b>4.2</b>	<b>Tamanho da janela de varredura da imagem .....</b>	<b>61</b>
<b>4.3</b>	<b>Resultados gerais.....</b>	<b>69</b>
<b>5</b>	<b>CONCLUSÃO.....</b>	<b>76</b>
<b>5.1</b>	<b>Conclusão final.....</b>	<b>76</b>
<b>5.2</b>	<b>Trabalhos futuros .....</b>	<b>77</b>
	<b>REFERÊNCIAS.....</b>	<b>78</b>

## 1 INTRODUÇÃO

A classificação digital de imagens de satélite tem ganhado, nas últimas décadas, reconhecimento como técnica para suprir a escassez dos mapeamentos temáticos. Com uma realidade geográfica cada vez mais complexa, novos sensores, com maior resolução espacial, encontram-se disponíveis no mercado aumentando potencialmente seu uso, tornando necessária a existência de ferramentas que auxiliem a análise espacial dos fenômenos que envolvam uma grande massa de dados. Estas novas imagens demandam novas técnicas de análise, pois oferecem um maior grau de detalhe, o que possibilita a identificação de áreas em função de suas propriedades espectrais e espaciais.

Nos últimos anos, com o aumento de satélites em órbita da Terra, o volume de dados coletados tornou-se muito grande e praticamente impossível de ser tratado por métodos convencionais de interpretação visual (Moreira, 2003). Sendo um grande estímulo para que pesquisas relacionadas à classificação automática de imagens fossem intensificadas.

As informações contidas em imagens de satélite podem ser extraídas através da classificação digital destas imagens. Existem vários métodos de classificação, que buscam identificar a informação de cada pixel da imagem, classificando-o em categorias de acordo com sua informação espectral.

Para classificar dados de diferentes origens as Redes Neurais Artificiais (RNA) são atualmente uma opção emergente.

As RNA funcionam conceitualmente de forma similar ao cérebro humano, tentando reconhecer regularidades e padrões. As RNA são capazes de aprender com a experiência e fazer generalizações baseadas no seu conhecimento previamente acumulado.

O mapeamento da ocupação da terra constitui uma das mais importantes atividades de geração de informações para gerenciamento e monitoramento de

ambientes agrícolas. E quando se tem como alvo lavouras de café é preciso ter em conta que estas estão inseridas num contexto ambiental, havendo, portanto, interferências múltiplas.

Minas Gerais se destaca entre os estados brasileiros em área plantada e quantidade produzida de café. Mas apesar de ser o estado de maior relevância para a produção do País com uma participação de 52,0% do total produzido no país (CONAB, 2012), Minas ainda não dispõe de dados precisos sobre a extensão e distribuição das áreas cafeeiras, dificultando o subsídio das atividades de planejamento de sua cafeicultura e garantia de sustentabilidade econômica, social e ambiental.

O conhecimento do ambiente em que o café está inserido permite um melhor planejamento da produção, visando o desenvolvimento sustentável e a obtenção de produtos com qualidade. Os produtos gerados a partir de um Sistema de Informação Geográfica (SIG) possibilitam aos pesquisadores e produtores rurais uma visualização e interpretação da atividade cafeeira, a obtenção de estimativas de produção e produtividade e uma melhor avaliação das influências ambientais.

Nos grandes projetos de mapeamento, a técnica de interpretação visual é ainda muito utilizada. Este processo feito pelo homem é muito eficaz, porém sujeito às falhas ocasionadas pelo cansaço, fadiga e etc. Outro fator importante no processo, é que nem sempre profissionais com a mesma competência possuem a mesma opinião sobre a imagem. Portanto, há uma tendência de utilização cada vez maior da classificação computacional, pela rapidez e facilidade em obter resultados (COSTA, 1999).

Os classificadores de imagens convencionais utilizados pelos SIG são inadequados para as necessidades de alta acurácia exigida pelos usuários (INPE, 2002). A fim de se conseguir melhores resultados, optou-se por criar um classificador de imagens baseado em Redes Neurais Artificiais.

## **1.2 Objetivos**

O objetivo deste trabalho é a criação de um algoritmo de classificação automática de áreas cafeeiras em imagens de satélite utilizando RNA, estimando a porcentagem de cobertura do solo.

### **1.2.1 Objetivos Específicos**

Como objetivos específicos têm-se:

- Criação de um algoritmo usando o software MATLAB, para a identificação automática de áreas cafeeiras em imagens do satélite Landsat 5 sensor TM, usando RNA;
- Avaliar o potencial das RNA na classificação;
- Avaliar o método proposto na identificação de áreas cafeeiras, mata, corpos d'água, área urbana e outros usos;
- Comparar esta metodologia com outras abordagens.

### **1.3 Organização da monografia**

Este trabalho encontra-se dividido em 5 capítulos. O capítulo 1 faz uma introdução sobre o tema abordado. No capítulo 2 está a revisão bibliográfica onde pode ser encontrado um resumo sobre todos os conceitos utilizados neste trabalho, encontra-se nesse capítulo: assuntos pertinentes sobre RNA como o neurônio biológico e o artificial, arquitetura das RNA, Multi-Layer Perceptron (MLP), Redes Neurais Artificiais convolutivas, aprendizado, backpropagation, software MATLAB e o toolbox de RNA, e também sobre sensoriamento remoto, imagens de satélite, a classificação e o problema da classificação automática do café. O capítulo 3 é destinado aos materiais e métodos utilizados no trabalho, abordando os seguintes tópicos: a origem dos dados que serão utilizados, o pré-processamento da imagem, a definição da arquitetura, o treinamento da rede neural e a validação dos resultados. No capítulo 4 estão os resultados obtidos. E no capítulo 5 a conclusão do trabalho.



## **2 REVISÃO BIBLIOGRÁFICA**

Este capítulo apresenta informações sobre os principais temas abordados no desenvolvimento deste trabalho, assim como os principais conceitos utilizados.

### **2.1 Redes Neurais Artificiais**

As Redes Neurais Artificiais (RNA) constituem um campo da Ciência da Computação ligado à Inteligência Artificial,. Tem como propriedade mais importante a capacidade de aprender por intermédio de exemplos (treinamento) e fazer inferências sobre o que aprendeu, melhorando gradativamente o seu desempenho.

São estruturas computacionais construídas com base no funcionamento do cérebro e seus neurônios, com o objetivo de simular nos computadores a capacidade de aprender do cérebro humano. Esta estrutura é composta de ligações entre neurônios, que trabalham em paralelo para classificar e generalizar dados de entrada em classes de saída. O aprendizado da rede é determinado por um processo repetitivo que tenta adequar os pesos a uma saída esperada para cada amostra de treinamento. Este ajustamento nas ligações entre os neurônios durante o processo de aprendizado é uma das mais importantes características das redes neurais artificiais. Tais redes usam o treinamento supervisionado realizado por um algoritmo chamado de retro-propagação do erro (Error Backpropagation), o qual é baseado na regra de aprendizagem que “corrige” o erro durante o treinamento (BOCANEGRA, 2002).

Diversas pesquisas têm sido realizadas utilizando RNA como instrumento de classificação de imagens digitais, como por exemplo, na detecção de focos de incêndio (TORINO e BARRETO, 2002); na classificação

de áreas agrícolas, na separação de culturas (VIEIRA, 2000); na medicina para a detecção de câncer em Mamogramas Digitalizados (KINOSHITA, MARQUES E FRERE, 2000); no desenvolvimento de métodos para a detecção de movimentos de objetos, através de sequência de imagens digitais (FERNANDEZ, CABALLERO et al., 2003), dentre outras.

A utilização de modelos de RNA em classificação de imagens digitais possibilita a incorporação não apenas de dados multiespectrais, mas de dados adquiridos por outras fontes, mesmo que não apresentem natureza espectral. Nessas situações, as RNA parecem desempenhar a tarefa de classificação de imagens tão bem, ou melhor, que as técnicas estatísticas, uma vez que não requerem que a natureza paramétrica dos dados a serem classificados seja explicitada (GALO et al., 2000).

E são capazes de reconhecer padrões, mesmo que os dados utilizados no treinamento sejam não-lineares, incompletos ou até mesmo contraditórios.

### **2.1.1 O cérebro e o neurônio biológico**

De acordo com Haykin (2001), o cérebro é um sistema de processamento de informação altamente complexo, não-linear e paralelo. Ele tem a capacidade de organizar seus constituintes estruturais, conhecidos por neurônios, de forma a realizar certos processamentos muito mais rápido que o mais ágil computador hoje existente.

Um neurônio é uma célula formada por três seções com funções específicas e complementares: corpo, dendritos e axônio. Os dendritos captam os estímulos recebidos em um determinado período de tempo e os transmitem ao corpo do neurônio, onde são processados. Quando tais estímulos atingirem determinado limite, o corpo da célula envia novo impulso que se propaga pelo axônio e é transmitido às células vizinhas por meio de sinapses. Este processo

pode se repetir em várias camadas de neurônios. Como resultado, a informação de entrada é processada, podendo levar o cérebro a comandar reações físicas. A Figura 2.1 ilustra de forma simplificada as partes de um neurônio.

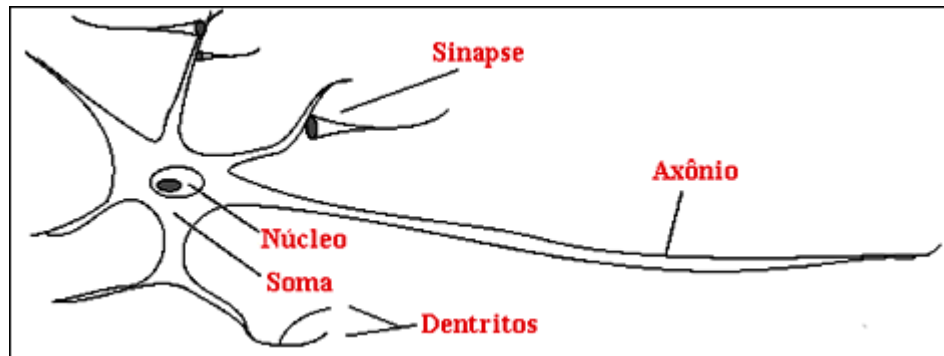


Figura 2.1 Modelo de um neurônio biológico

### 2.1.2 Neurônio artificial

A busca por um modelo computacional que simule o funcionamento das células do cérebro teve início nos anos 40, com o trabalho de McCulloch e Pitts em 1943. Em 1958 Rosenblatt propôs um método inovador de aprendizagem para as redes neurais artificiais denominado Perceptron. No final dos anos 80, o entusiasmo ressurgiu graças a avanços metodológicos importantes e ao aumento dos recursos computacionais disponíveis.

O modelo matemático de neurônio artificial da Figura 2.2 é uma simplificação do modelo apresentado por Haykin (2001).

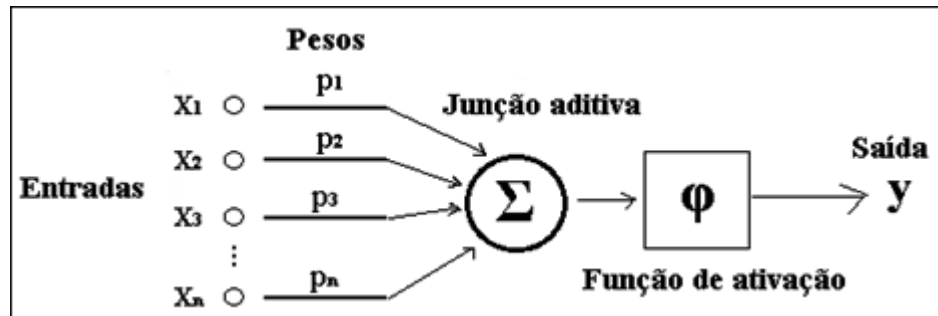


Figura 2.2 Modelo matemático de um neurônio

Este modelo é composto por três elementos básicos:

- Um conjunto de  $n$  conexões de entrada ( $x_1, x_2, \dots, x_n$ ), caracterizadas por pesos ( $p_1, p_2, \dots, p_n$ );
- Um somador ( $\Sigma$ ) para acumular os sinais de entrada;
- Uma função de ativação ( $\phi$ ) que limita o intervalo permissível de amplitude do sinal de saída ( $y$ ) a um valor fixo.

As redes neurais artificiais são organizadas em camadas que compõem sua topologia ou arquitetura. Existem redes neurais de camada simples (Perceptron) constituídas por um grupo de neurônios arranjados em apenas uma camada, e as redes de múltiplas camadas, conhecidas com MLP (Multi-Layer Perceptron), formadas por várias camadas intermediárias ou pela combinação de várias redes de camadas simples, na Figura 2.3 temos o exemplo de uma rede MLP.

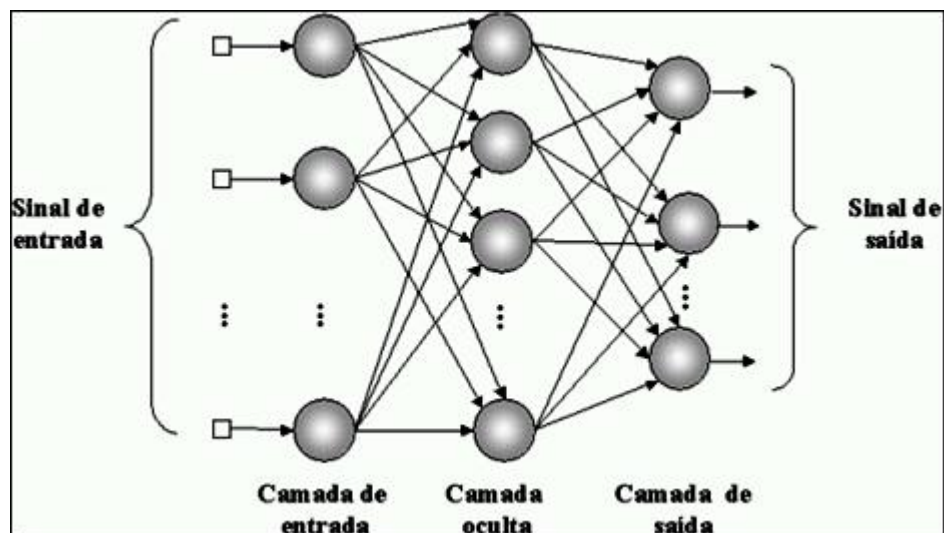


Figura 2.3 Rede de múltiplas camadas

### 2.1.2 Arquitetura das Redes Neurais Artificiais

A arquitetura de uma rede refere-se à maneira como os elementos de processamento, neurônios e suas camadas, são organizados, o que afeta o desempenho da rede, uma vez que sua estrutura está intimamente ligada ao algoritmo de aprendizado usado na fase de treinamento da rede.

A arquitetura de uma rede neural é definida pelo número de camadas (camada única ou múltiplas camadas), pelo número de nós em cada camada, pelo tipo de conexão entre os nós e por sua topologia (HAYKIN, 2001).

A camada de entrada de uma rede neural é aquela na qual os padrões são apresentados à rede. Esta camada se comunica com as demais por meio de um sistema de conexões ponderadas; as camadas intermediárias (ou ocultas) são responsáveis por grande parte do processamento, podendo ser consideradas como extratoras de características; e a camada de saída é aquela onde o resultado final é concluído e apresentado.

Segundo Haykin (2001), adicionando-se uma ou mais camadas ocultas, tornamos a rede capaz de extrair estatísticas de ordem elevada.

### **2.1.1 Multi-Layer Perceptron**

Tipo de rede neural conhecida na literatura como rede de múltiplas camadas. Este tipo de rede neural permite a execução de tarefas como a simulação de séries temporais, reconhecimento de padrões, entre outras aplicações. Cada neurônio de uma camada conecta-se com a totalidade de neurônios de suas camadas adjacentes. Estas conexões também denominadas pesos sinápticos, transformam o sinal de entrada da rede ativando os neurônios pelas camadas internas até a camada de saída, onde se obtém a resposta desejada (MEDEIROS, 2003).

No caso particular de aplicações em classificação de imagens de sensoriamento remoto, diversos trabalhos (HEPNER, 1990; BENEDIKTSSON et al., 1990; LIU et al., 1991) fizeram uso de RNA, aplicando uma rede de multicamadas para resolver o problema de classificação. Este tipo de rede caracteriza-se por assumir regiões de decisão semelhantes àsquelas formadas por um classificador estatístico, porém com entradas não correlacionadas e distribuições diferentes para os dados (LIPPMANN, 1987).

As redes do tipo MLP têm sido utilizadas com sucesso para a solução de vários problemas envolvendo altos graus de não-linearidade. O algoritmo de aprendizado mais utilizado para o treinamento destas redes é o algoritmo retro-propagação (backpropagation) (PICOLI, 2006). Seu treinamento é do tipo supervisionado e é baseado em uma regra de aprendizagem que “corrige” o erro durante o treinamento (BOCANEGRA, 2002).

De acordo com VIEIRA (2000), as principais características, desta rede, são:

- Adequado para problemas não linearmente separáveis;
- Rede neural com, no mínimo, três camadas, sendo: camada de entrada, camada(s) intermediária(s) ou escondida(s), camada de saída. Sendo que um neurônio interliga vários outros neurônios de outra camada;
- Vários neurônios podem ser combinados para computar problemas mais complexos;
- Possui um algoritmo de aprendizado, podendo assim melhorar seu desempenho;
- O algoritmo de aprendizado deste modelo funciona por ciclos. Em cada ciclo, um conjunto de padrões é apresentado à rede neural, e calculado o erro em relação ao resultado esperado. O erro é usado para atualizar os pesos, e então um novo ciclo é aplicado;
- Possuem entradas e saídas binárias que assumem os valores +1 ou -1;
- A função de ativação é a função sigmoide.

### **2.1.2 Redes Neurais Artificiais convolutivas**

Uma rede convolutiva é um Perceptron de múltiplas camadas projetado especificamente para reconhecer formas bidimensionais, por exemplo, uma imagem com um alto grau de invariância quanto à translação, escalonamento, inclinação e outras formas de distorção (HAYKIN, 2001).

A Figura 2.4 ilustra um exemplo de rede neural convolutiva.

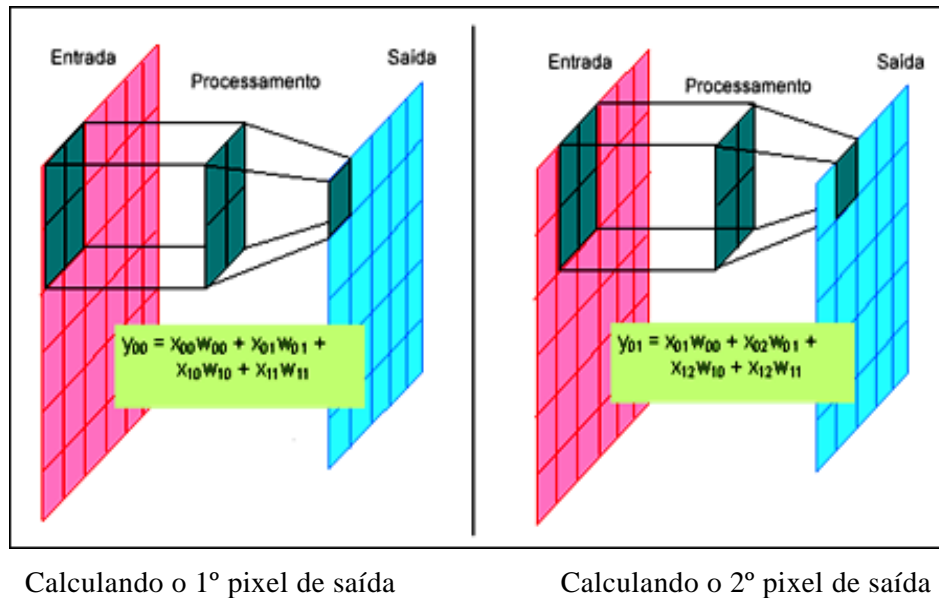


Figura 2.4 Exemplo de rede neural convolutiva

Por exemplo, a convolução de uma imagem ( $N \times N$ ) com um kernel ( $K \times K$ ) pode ser entendida como uma janela deslizante ( $K \times K$ ) sobre a imagem de entrada iterativamente. Para cada posição da janela, um pixel de saída é gerado. Uma rede convolutiva possui diversas camadas e cada uma com diversos mapas. A primeira camada tem apenas um mapa característico que é a imagem de entrada em si. Nas camadas seguintes, cada mapa característico mantém um certo número de kernels igual ao número dos mapas na camada anterior. O tamanho de cada kernel em um mapa é um parâmetro de projeto. Os valores de pixel em um mapa são obtidos por convolução do kernel com os mapas correspondentes da camada anterior. O número de mapas de recurso na última camada é igual ao número de opções de saída, ou seja, resultados desejados.



### 2.1.3 Aprendizado

A etapa de aprendizado de uma RNA consiste em um processo iterativo de ajuste de parâmetros da rede, os pesos das conexões, que guardam, ao final do processo, o conhecimento que a rede adquiriu do ambiente externo (BRAGA et al., 2007).

Talvez a mais importante forma de classificar as RNA seja quanto à forma de aprendizado que pode ser supervisionada e não supervisionada.

Segundo Haykin (2001), uma rede neural aprende acerca do seu ambiente através de um processo iterativo de ajustes aplicados a seus pesos sinápticos.

Segundo Ribeiro e Centeno (2002) treinar uma rede neural significa ajustar a sua matriz de pesos, de forma que o vetor de saída coincida com certo valor desejado para cada vetor de entrada, de forma supervisionada ou não. E para determinar o número de épocas de treinamento é necessário encontrar um equilíbrio entre a porcentagem de acerto do treinamento e a porcentagem de acerto do teste, pois após um determinado número de épocas de treinamento ocorre o *overfitting*, que é quando a rede decora os resultados, podendo levar a rede a uma perda de generalização, atrapalhando assim o teste final.

No aprendizado supervisionado considera-se que o analista possui o conhecimento sobre o ambiente, é capaz de representá-lo por um conjunto de amostras, são sucessivamente apresentadas à rede conjuntos de padrões de entrada e seus correspondentes padrões de saída, já que o ambiente é desconhecido pela rede neural. A rede realiza um ajustamento dos pesos das conexões entre os elementos de processamento, segundo uma determinada lei de aprendizagem, até que o erro entre os padrões de saída gerados pela rede alcance um valor mínimo desejado. Desta forma o conhecimento do ambiente disponível ao analista é transferido à rede neural através do treinamento (HAYKIN, 2001).

No aprendizado não supervisionado não há um crítico para supervisionar o processo de aprendizagem e nem exemplo da função a ser aprendida pela rede. A própria rede “analisa” os conjuntos de dados apresentados a ela, determina algumas propriedades dos conjuntos de dados e “aprende” a refletir estas propriedades na sua saída. Uma vez ajustada à rede as regularidades estatísticas dos dados de entrada, ela desenvolve a habilidade de formar representações internas para codificar as características da entrada e assim criar automaticamente novas classes (HAYKIN, 2001; MURION, 1996).

Os exemplos mais conhecidos de algoritmos para aprendizado supervisionado são a regra delta e a sua generalização para redes de múltiplas camadas, o algoritmo backpropagation, esse algoritmo, derivado da Regra Delta Generalizada (HAYKIN, 1994), permite um ajuste de pesos em cada uma das camadas da rede e é projetado para minimizar a soma do erro médio quadrático entre a saída da rede e a saída desejada.

#### **2.1.4 Backpropagation**

A principal característica do algoritmo *backpropagation* é a maneira interativa pela qual os erros utilizados para adaptar os pesos são propagados para trás, isto é, a partir da camada de saída para as camadas anteriores.

Galo (2000) resume o processo de treinamento em duas fases distintas, começando com a definição de um conjunto arbitrário de pesos para as conexões da rede. Na primeira, um vetor de treinamento, com a respectiva saída desejada é apresentado à rede e propagado através de suas camadas para computar uma saída para cada elemento de processamento. As saídas dos nós da última camada são, então, comparadas com as saídas desejadas e a partir disso são calculados os termos de erro. A segunda fase envolve um retrocesso, ou seja, uma passagem de volta através da rede a partir da última camada, durante a qual, o erro é

repassado para cada elemento de processamento e os pesos correspondentes são convenientemente alterados. Em um treinamento bem sucedido, este erro diminui com o aumento do número de iterações e o procedimento converge para um conjunto estável de pesos.

De acordo com VIEIRA (2000), apesar do grande sucesso do modelo de retro-propagação, existem alguns problemas que se deve citar, como o longo período de treinamento, principalmente para problemas complexos e mínimos locais. Podendo ocorrer também os pesos serem justados para valores muito grandes, levando a paralisar a rede.

Devido os problemas citados acima foi proposta por Rumelhart, Hinton e Williams em 1986 uma alternativa chamada de “momentum”, para diminuir o tempo de treinamento, assegurando um maior grau de estabilidade para a rede, mostrando-se eficiente em alguns casos. O termo momentum especifica a quantidade que será acrescentada da variação do velho para o novo peso.

## **2.2 MATLAB**

MATLAB é um sistema interativo de matrizes, de alta performance, que pode ser usado tanto para o ensino de matemática fundamental quanto para cálculos complexos de engenharia. O nome é uma abreviação de MATrix LABoratory (MATLAB) e foi originalmente desenvolvido com a intenção de facilitar o acesso a matrizes. Foi desenvolvido por “The Mathworks, Inc” no final da década de 70, contendo constantes atualizações e aperfeiçoamentos.

Baseia-se no conceito que os dados podem ser representados como matrizes e, desse modo, a maioria das operações de análise numérica podem ser realizadas usando álgebra linear. Evita-se, assim, o uso excessivo de algoritmos de loops, pois as rotinas são feitas considerando as propriedades matemáticas das operações com matrizes, vetores e escalares.

O software MATLAB contém uma série de comandos versáteis para operações matemáticas, estatísticas e produção de gráficos de alta qualidade. Assim, ameniza-se os problemas que comumente são encontrados ao se efetuar até as mais simples análise de dados em programas (MIDDLETON, 2000).

O MATLAB ainda possui uma família de aplicativos específicos, os *toolboxes*, que são caixas de ferramentas, que permitem a criação de funções usadas para resolver determinados problemas tais como: otimização, manipulação algébrica, redes neurais, processamento de sinais, simulação de sistemas dinâmicos, entre outros, que estendem sua funcionalidade. O conjunto de *toolboxes*, que podem ser organizados conforme necessidades específicas, tornam o MATLAB uma poderosa ferramenta de análise de dados.

### **2.2.1 Toolbox de RNA do MATLAB**

Neural Network Toolbox é uma ferramenta para elaboração, execução, visualização e simulação de redes neurais contida no software MATLAB. A ferramenta fornece suporte completo para projetar e gerenciar redes neurais, além de simplificar a criação de funções e redes neurais personalizadas.

O Toolbox de Redes Neurais do MATLAB possui ampla versatilidade e flexibilidade, haja visto que o seu uso possibilita a aplicação dos mais variados tipos de redes neurais além de permitir a modificação de redes já existentes, como alterações no número de camadas ou mesmo algoritmos de treinamento com uma facilidade particular de inserção.

Para a criação de uma RNA no software MATLAB faz-se uso da função *newff*. Os parâmetros de entrada necessários são: algoritmo de treinamento, função transferência, número máximo de iterações, número de camadas escondidas e o valor do erro mínimo desejado. Para o treinamento da RNA utiliza-se a função *train* e para a classificação a função *sim*.

A versão do toolbox de redes neurais utilizada disponibiliza uma ferramenta muito útil, o Graphical User Interface (GUI). Nesta janela, pode ser visualizada toda a atividade da rede na fase de treino, incluindo um esquema gráfico da arquitetura, o nome dos algoritmos utilizados, o n.º de iterações efetuadas, o tempo, a performance, o gradiente, e a visualização de gráficos. A Figura 2.5 mostra a janela parcial deste GUI, para a rede criada.

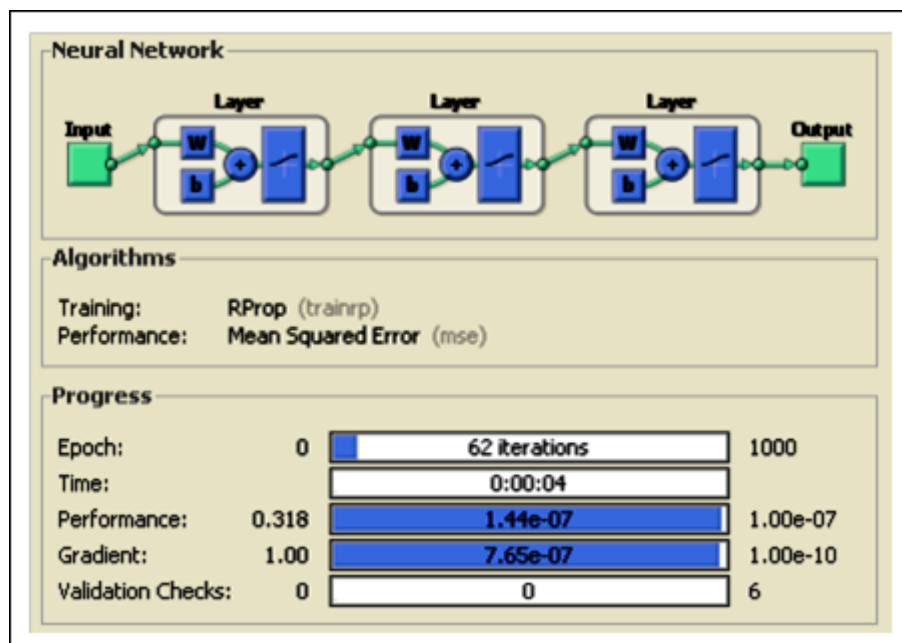


Figura 2.5 Modelo Graphical User Interface

Mais informações podem ser encontradas no site <http://www.mathworks.com/>.

## 2.3 SPRING

O SPRING (Sistema de Processamento de Informações Georreferenciadas) é um SIG desenvolvido pelo Instituto Nacional de Pesquisas Espaciais (INPE) em São José dos Campos/SP para ambientes UNIX e Windows (SPRING, 2012). Tem se mostrado uma opção altamente atrativa na área de geoprocessamento, pois pode ser considerado um software de domínio público e constitui um produto desenvolvido com tecnologia totalmente nacional.

O sistema SPRING constitui-se de quatro aplicativos ou programas executáveis:

- Impima – utilizado para leitura de imagens e conversão para o formato GRIB;
- SPRING – programa principal do sistema onde serão modelados os dados;
- Scarta - programa que permite a elaboração de cartas a partir de dados previamente tratados no programa SPRING;
- Iplot – utilizado para abrir um arquivo IPL, criado pelo SCARTA (SPRING, 2012).

## 2.4 Sensoriamento remoto

O rápido desenvolvimento de novas tecnologias para coleta de informações geográficas, com o a inovação propiciada pelos sensores remotos, permitiu ao homem ampliar o conhecimento sobre a superfície da Terra e o uso do computador e de sistemas avançados para o tratamento das informações espaciais trouxe maior precisão na obtenção dos dados. Essas novas tecnologias,

conhecidas como geotecnologias, que incluem os sistemas de informação geográfica e o sensoriamento remoto, tornaram-se ferramentas indispensáveis no processo de elaboração de mapas.

Sistemas de Informação Geográfica (SIG) são programas utilizados para o tratamento computacional de dados geográficos, ou seja, dados que representam objetos e fenômenos em que a localização geográfica é uma característica inerente e indispensável. O SIG armazena a geometria e os atributos dos dados que estão georreferenciados, isto é, localizados na superfície terrestre segundo uma projeção cartográfica. Além do armazenamento, esses sistemas realizam o tratamento, a análise e visualização das geoinformações, possibilitando a apresentação ao usuário final de forma compreensiva e facilmente interpretável. Uma característica básica do SIG é a de tratar relações espaciais entre objetos geográficos. Portanto, aplicações em estudos ambientais podem abranger desde a escala global à regional ou local (CÂMARA et al., 1996).

O monitoramento dos recursos naturais por meio das geotecnologias permite a rápida detecção de alterações ambientais, pois os satélites realizam a varredura da superfície terrestre de forma repetitiva e em um curto espaço de tempo (VIEIRA et al., 2007). Dessa forma, o emprego das geotecnologias e da cartografia digital tem possibilitado ao Brasil, a partir da década de 90, o mapeamento de seu ambiente físico com maior rapidez e menor custo, ainda que de forma modesta (MEIRELES et al., 2007). Tal mapeamento é de extrema importância no processo de planejamento do uso racional e sustentável dos recursos naturais pelas atividades antrópicas, dentre elas a agropecuária.

Na área do sensoriamento remoto, um aspecto que tem experimentado maior aprimoramento é a resolução espacial. Esta evolução nos sistemas sensores tem revolucionado os paradigmas da interpretação de imagens,

tornando viável a identificação de construções com muito mais detalhes, bem como outros objetos que anteriormente não eram.

Os sistemas de aquisição de dados de Sensoriamento Remoto, definidos como sistema sensores, constituem-se de qualquer equipamento capaz de transformar a radiação eletromagnética refletida pelos alvos da superfície terrestre em um sinal passível de ser convertido em informações sobre o meio ambiente (NOVO, 1989).

A distinção entre os padrões de uso da terra é possível devido ao comportamento específico dos objetos com a radiação eletromagnética, em função do comprimento de onda e das características bio-físico-químicas dos alvos.

Os usuários dessas imagens necessitam de uma análise qualitativa e quantitativa. A execução da avaliação quantitativa é realizada eficientemente por meio de sistemas computacionais, pois pode ser processada de maneira digital. A metodologia para a análise quantitativa das imagens digitais é chamada de classificação digital de imagens (RICHARDS, 1993).

A classificação de imagens de Sensoriamento Remoto consiste em estabelecer um processo de decisão no qual um pixel ou um grupo de pixels é definido como pertencente a uma determinada classe. Essa classificação representa uma boa opção na coleta de dados sobre a superfície terrestre reduzindo custo e tempo necessários à sua realização. A classificação de imagens multiespectrais visa à categorização da cobertura da terra distinguindo as composições de diferentes materiais superficiais.

A identificação de feições em imagens capturadas por sensoriamento remoto é feita através da habilidade do analista em diferenciar padrões, utilizando seu conhecimento intuitivo e o de fotointerpretação sobre a área de estudo. O intérprete fica limitado de executar esta mesma função com as imagens digitais, pois estas são multiespectrais. Além disto, o intérprete não tem



acuidade visual para discriminar o limite da resolução radiométrica dos sensores atuais. Portanto a interpretação visual de imagens digitais gera produtos com algumas limitações (BRONSVELD et al., 1994).

O uso de RNA, aliado ao aumento de variáveis derivadas da imagem, que oferece a abordagem de classificação baseado em regiões, é uma alternativa viável e interessante no sensoriamento remoto, especialmente na classificação de imagens de alta resolução espacial.

### **2.2.2 Produtos do sensoriamento remoto**

Um dos produtos do sensoriamento remoto é a imagem digital. Essa imagem traz consigo informações coletadas pelo sensor no momento de sua passagem por determinada área. As imagens geradas por sensores orbitais são imagens chamadas matriciais, pois têm uma natureza discreta, ou seja, é formada de elementos independentes, dispostos na forma de uma matriz (SCHNEIDER, 2001). Cada elemento dessa matriz tem sua localização definida em um sistema de coordenadas do tipo linha e coluna, representados por  $x$  e  $y$ , respectivamente. A projeção de uma cena em um plano, normalmente representada como uma matriz de valores de intensidade luminosa, recebe o nome de imagem. Como os computadores não manipulam dados analógicos é necessário converter uma imagem contínua em sua forma digital.

A imagem digital corresponde à representação numérica do objeto, é uma função  $f(x, y)$  quantificada e amostrada, sendo a sua menor unidade denominada de *pixel* (picture element). Uma imagem digital pode ser considerada como sendo uma matriz cujos índices de linhas e de colunas identificam um ponto na imagem, e o correspondente valor do elemento da matriz identifica a intensidade luminosa naquele ponto. Quanto mais pixels

melhor a resolução e a qualidade da imagem. Na Figura 2.6 é possível visualizar a representação de uma imagem com 255 tons de cinza (SILVA, 2005).




Figura 2.6 Representação de uma imagem digital

A cada instante, uma pequena área do terreno é coberta por um sensor e o total de energia desta unidade de área é armazenado sob a forma de um número digital através do processo de varredura. Tratando-se de uma imagem colorida ou multiespectral, várias matrizes são necessárias para armazenar os valores correspondentes à informação multiespectral desta imagem.

As imagens são classificadas em relação ao número de cores. Esta diferença na representação de uma imagem digital é decorrência do número de bits utilizado pelo dispositivo de aquisição na captura da mesma (SOUZA, 2000). Assim temos: imagem binária, na qual os pixels assumem apenas dois valores: 0 e 1, representando o preto e o branco respectivamente; imagem monocromática, cujos pixels podem assumir uma faixa de valores variando do preto ao branco, correspondentes aos níveis de cinza; imagem colorida, pode ser vista como a sobreposição de três imagens monocromáticas, cada uma delas

representando as intensidades das cores vermelho, verde e azul que compõem a imagem original.

### 2.2.3 Bandas

Moreira (2003) comenta que as cenas coletadas pelos sensores podem ser imageadas por diferentes categorias de satélite, como os militares, científicos e meteorológicos. Os sensores utilizados para dados em nível orbital estão geralmente voltados para os estudos dos recursos naturais e operam em diferentes números de bandas que estão associadas aos comprimentos de onda. Dentre os sensores multiespectrais mais utilizados podem-se citar os sensores Thematic Mapper (TM) dos satélites Landsat, High Resolution Visible (HRV) do satélite SPOT, e os sensores embarcados nos satélites IKONOS e QUICKBIRD.

O TM opera em 7 faixas espectrais, também chamadas bandas espectrais do espectro eletromagnético, que correspondem a comprimentos de onda específicos de cada sensor. A resolução espacial é entendida como a capacidade do sensor em captar e registrar a menor área possível no terreno. No caso do sensor TM, a resolução espacial é de 30 x 30m no terreno, ou seja, tudo que estiver na superfície terrestre em uma área de 900m<sup>2</sup> será registrado em um único pixel da imagem produzida. Para a banda 6 essa resolução espacial é igual a 120 x 120m (ANDRADE, 2011).

As aplicações das bandas espectrais do satélite TM Landsat, segundo Silva e Francisco (2012) são:

- Banda 1 (0,450 - 0,520  $\mu m$ ) Azul: Útil para mapeamento de águas costeiras, diferenciação entre solo e vegetação, mapeamento de florestas, entre outras.

- Banda 2 (0,520 - 0,600  $\mu m$ ) Verde: Corresponde à reflectância da vegetação verde e sadia. Também é útil para identificação de feições culturais.
- Banda 3 (0,630 - 0,690  $\mu m$ ) Vermelho: Útil para discriminação entre espécies de plantas e delinear solo e feições culturais. Permite um bom contraste entre áreas ocupadas com vegetação e aquelas sem vegetação. Apresenta bom contraste entre diferentes tipos de cobertura vegetal (ex.: campo, cerrado e floresta). É a banda mais utilizada para delimitar manchas urbanas e identificar áreas agrícolas.
- Banda 4 (0,760 - 0,900  $\mu m$ ) Infravermelho próximo: É útil para identificação de culturas agrícolas, enfatizando a diferenciação solo/agricultura e água/solo. Apresenta sensibilidade à morfologia do terreno, permitindo o mapeamento de corpos d'água como rios, lagos, reservatórios, áreas úmidas de várzeas, geologia e geomorfologia e macrófitas aquáticas;
- Banda 5 (1,550 - 1,750  $\mu m$ ) Infravermelho médio: Apresenta sensibilidade ao teor de umidade das plantas, permitindo detectar estresse na vegetação causado pela falta de água. Também é usada para obter informações sobre a umidade do solo;
- Banda 6 (10,40 - 12,50  $\mu m$ ) Infravermelho termal: Usada para estudos de propriedades termais de rochas, solos, vegetação e água. Também utilizada para mapeamento da temperatura de águas oceânicas superficiais.
- Banda 7 (2,080 - 2,350  $\mu m$ ) Infravermelho médio: Importante para estudos nas áreas de Geomorfologia, Solos e Geologia. Muito usada para a discriminação de tipos de rochas e no estudo de solos, como também para detectar o grau de umidade em que se encontram os solos.

### 2.3 Classificação de imagens de satélite

A classificação digital de imagens é um procedimento utilizado para separar e identificar os objetos na superfície terrestre detectado pelos sensores dos satélites. Segundo CRÓSTA (1992) a classificação digital é um processo que extrai informações das imagens digitais para o reconhecimento de padrões espectrais e objetos homogêneos com o auxílio da inspeção visual humana.

O INPE (2000) descreve que o processo de classificação pode ser basicamente dividido em dois tipos de classificadores: classificadores por pixel e os por região. Os classificadores por pixel utilizam as informações espectrais isoladas referentes a cada pixel para agregar as regiões homogêneas. Enquanto que os classificadores por região utilizam não somente as informações espectrais de cada pixel, mas também as informações espaciais que envolvem a relação entre os pixels e seus vizinhos.

A distinção entre os padrões de uso da terra é possível graças ao comportamento espectral específico dos objetos ao longo do espectro eletromagnético, ou seja, estes objetos da superfície terrestre interagem (reflectância, absorbância e transmitância) com a radiação eletromagnética de maneira diferenciada, em função do comprimento de onda, de acordo com suas características bio-físico-químicas.

De acordo com Ribeiro e Centeno (2002), a melhoria de informação visual para a interpretação humana e o processamento de dados de cenas para percepção automática por meio de máquinas, é o principal incentivador ao estudo dos métodos de processamento digital de imagens.

### 2.3.1 O problema da identificação automática de café

Para mapear café, classificadores automáticos são raramente usados. Isso porque a resposta espectral dessa cultura é bastante complexa, em função das diversas variáveis que envolvem a caracterização da mesma e do ambiente em que está inserida (VIEIRA et al, 2006), tais como, variações do estágio fenológico, vigor vegetativo, espaçamento das plantas nas lavouras e dos tratos culturais utilizados, existência de culturas intercalares, maior sombreamento devido ao relevo acidentado e baixa resolução espacial das imagens Landsat utilizadas. Além disso, sua resposta espectral se assemelha muito a da mata nativa, como visto na Figura 2.7.




Figura 2.7 Resposta espectral da mata e do café (ANDRADE, 2011).

Moreira et al. (2004) afirmam que, embora a cultura do café apresente variações no comportamento espectral devido a fatores como espaçamento, idade e época do ano, a mesma pode ser identificada e mapeada em imagens de satélites com razoável precisão.

## 2.4 Índice Kappa

A avaliação da acurácia e uma classificação pode ser obtida por meio de coeficientes de concordância derivados da matriz de confusão. Congalton (1991) relata que o uso do coeficiente Kappa é satisfatório na avaliação da precisão de uma classificação temática, pelo fato de levar em consideração toda a matriz de confusão no seu cálculo, inclusive os elementos de fora da diagonal principal, os quais representam as discordâncias na classificação, diferentemente da exatidão global, por exemplo, que utiliza somente os elementos diagonais (concordância real).

O coeficiente Kappa é classificado, neste trabalho de acordo com a Tabela 2.1, adaptada de Galparsoro e Fernández (2001).

Tabela 2.1 Valor para avaliar o grau de concordância a partir do índice Kappa.

<b>Valor do Kappa</b>	<b>Concordância</b>
< 0,20	Pobre
0,21 – 0,40	Fraca
0,41 – 0,60	Moderada
0,61 – 0,80	Boa
0,81 – 1,00	Muito Boa

### **3 MATERIAIS E MÉTODOS**

O desenvolvimento deste trabalho teve como objetivo a criação de um algoritmo usando o software MATLAB 7.8.0.347 (R2009a) para a classificação automática de áreas cafeeiras em imagens de satélite utilizando Redes Neurais Artificiais, em um Notebook Dual Core 2.2GHz, 3GB de memória RAM e Sistema Operacional Windows 7 Professional de 64bits.

Para o desenvolvimento deste trabalho, baseado em Redes Neurais Artificiais, foram necessárias as seguintes etapas: definição do problema; pré-processamento dos dados; coleta dos dados de treinamento e de teste; definição da arquitetura da rede; treinamento e teste; validação da RNA.

#### **3.1 Materiais**

Os materiais usados neste trabalho e bem como os programas utilizados durante o desenvolvimento serão descritos a seguir.

##### **3.1.1 Área de estudo**

A área de estudo escolhida para esse trabalho foi a cidade de Três Pontas localizada no Sul de Minas Gerais, como mostra a Figura 3.1. Posiciona-se geograficamente entre as coordenadas 21° 17' 10.07'' S a 21° 27' 57.41'' S e 45° 30' 4.69'' W a 45° 45' 3.33'' W, com uma área total de 510 km<sup>2</sup>. A altitude média do município é de 905 metros, sendo que a máxima atinge 1.234 metros na Serra de Três Pontas. A região é cortada por três redes de drenagem principais, que deságuam na Represa de Furnas.



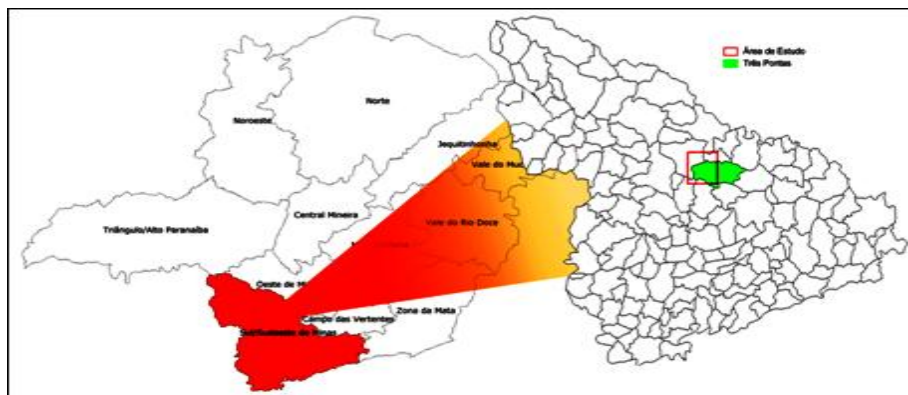


Figura 3.1 Localização da área de estudo: Três Pontas, região sul do estado de Minas Gerais (Adaptado de ANDRADE, 2011).

É uma das principais regiões produtoras de café do país representando 70% da renda agrícola. É uma região que pode ser considerada privilegiada para o mapeamento da cultura cafeeira, pois apresenta um relevo suave ondulado, que permite maior incidência de luz solar na cultura, obtendo assim uma melhor resposta espectral (SOUSA et al.,2009). De acordo com Vieira et al. (2006) a região apresenta uma cafeicultura em relevo mais suavizado e áreas de café contíguas.

### 3.1.2 Imagens TM/Landsat 5

Os dados multiespectrais utilizados para a classificação automática, correspondem a imagens orbitais TM/Landsat 5, bandas 3, 4 e 5 para a região de Três Pontas, com data de passagem de 16/07/2007 adquiridas junto ao INPE. A Figura 3.2 mostra as bandas da imagem utilizadas na classificação.




Figura 3.2 Imagens TM/Landsat 5, bandas 3, 4 e 5 da região de Três Pontas, com máscara de drenagem e área urbana (ANDRADE, 2011).

Para a validação da classificação, foi utilizado o Mapa de Uso e Ocupação da Terra de Três Pontas – MG (EPAMIG, 2012), classificado visualmente e conferido em campo (Figura 3.3).

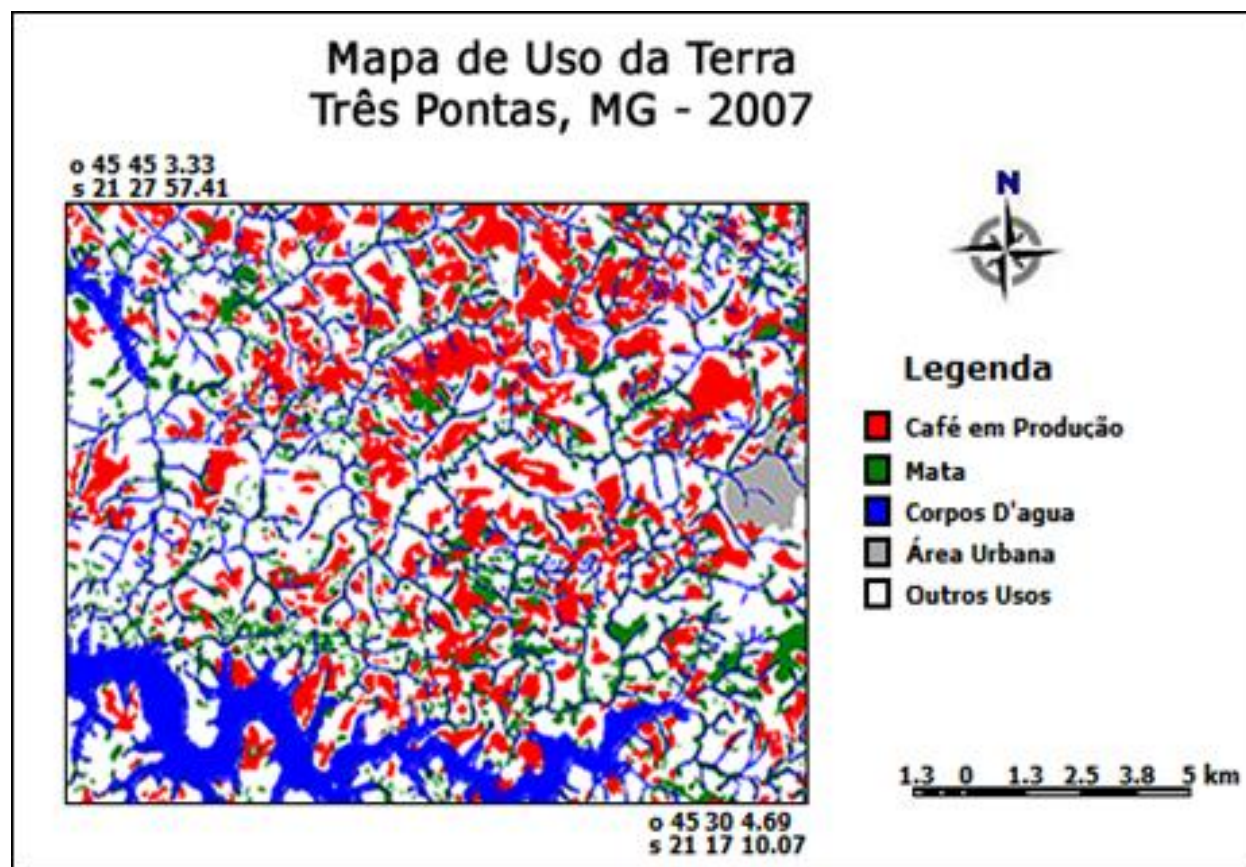


Figura 3.3 Mapa de Uso e Ocupação da Terra de Três Pontas – MG (EPAMIG, 2012).

### 3.1.3 Ferramentas computacionais utilizadas

#### MATLAB

O MATLAB é um sistema para cálculo científico que proporciona um ambiente de fácil utilização com uma notação intuitiva, podendo funcionar como uma calculadora ou como uma linguagem de programação científica (FORTRAN, Pascal, C, etc.). Entretanto, os comandos do MATLAB são mais próximos da forma como escrevemos expressões algébricas, tornando mais simples o seu uso. O ambiente MATLAB permite a realização de algoritmos numéricos sobre matrizes com o mínimo de programação. Além disso, é possível a criação e manipulação de matrizes sem a necessidade de dimensionamento prévio e a manipulação das variáveis pode ser realizada de forma interativa. O termo “*MATLAB*” tem origem na conjugação dos termos “*MATrix*” e “*LABoratory*”.

Além do ambiente interativo, outra facilidade do MATLAB é a possibilidade de execução de arquivos texto contendo uma sequência de instruções definidas pelo usuário. Esses arquivos texto, que têm extensão ‘.m’, podem ser criados e editados dentro ou fora do seu ambiente. O MATLAB apresenta uma série de comandos, operadores e funções primitivas, organizadas por categorias, assim como rotinas específicas de diversas áreas da engenharia, organizadas em bibliotecas denominadas *Toolboxes*. Existem *toolboxes* para estatística, processamento de sinal, processamento de imagem, controle, cálculo simbólico, etc.

*Image Processing Toolbox*™ é um programa criado para manipulação de imagens, análise de imagem digital, visão computacional e processamento de imagem digital. Os recursos incluem leitura e escrita de arquivos de imagem, transformações de espaço de cores linear, filtragem, morfologia matemática, análise de textura, reconhecimento de padrões, estatísticas de imagem e outros. A *toolbox* de processamento de imagens é a

parte mais interessante do MATLAB para área de segmentação de imagens (MATLAB, 2010).

*Neural Network Toolbox*™ fornece ferramentas para a concepção, implementação, visualização e simulação de redes neurais. As redes neurais são utilizadas para aplicações onde a análise formal seria difícil ou impossível, tais como reconhecimento de padrões e de identificação de sistemas não-lineares e controle. Neural Network Toolbox suporta redes feedforward, redes de base radial, dinâmicas, mapas auto-organizáveis, e outros paradigmas comprovados. O Toolbox é baseado sobre o objeto de rede. Este objeto contém informações sobre tudo que diz respeito a rede neural, por exemplo, o número e a estrutura das suas camadas, a conectividade entre as camadas, etc. MATLAB fornece funções de alto nível de criação de rede, como *newlin* (criar uma camada linear), *newp* (criar um perceptron) ou *newff* (criar uma rede *feed-forward backpropagation*) (MATLAB, 2010).

## **SPRING**

O SPRING (Sistema de Processamento de Informações Georreferenciadas) é um sistema de informação geográfico (SIG) desenvolvido pelo Instituto Nacional de Pesquisas Espaciais (INPE) em São José dos Campos/SP para ambientes UNIX e Windows (SPRING, 2012). Tem se mostrado uma opção altamente atrativa na área de geoprocessamento, pois pode ser considerado um software de domínio público e constitui um produto desenvolvido com tecnologia totalmente nacional.

O SPRING é foi utilizado para realizar o pré-processamento das imagens. A restauração da imagem para 10m, a criação da mascara de drenagem que é um buffer criado ao longo das linhas de drenagem em cada uma das três bandas, além da classificação visual foram realizadas com o software SPRING. Para o desenvolvimento da máscara, foi utilizada a

Linguagem Espacial para Geoprocessamento Algébrico (LEGAL), do próprio SPRING (SPRING, 2012).

### 3.2 Métodos

Para descrever a metodologia será utilizado o diagrama de blocos representado na Figura 3.4 contendo todos os procedimentos necessários para a execução deste trabalho. Nas seções que seguirão será explicado detalhadamente cada nível necessário ao desenvolvimento do software.

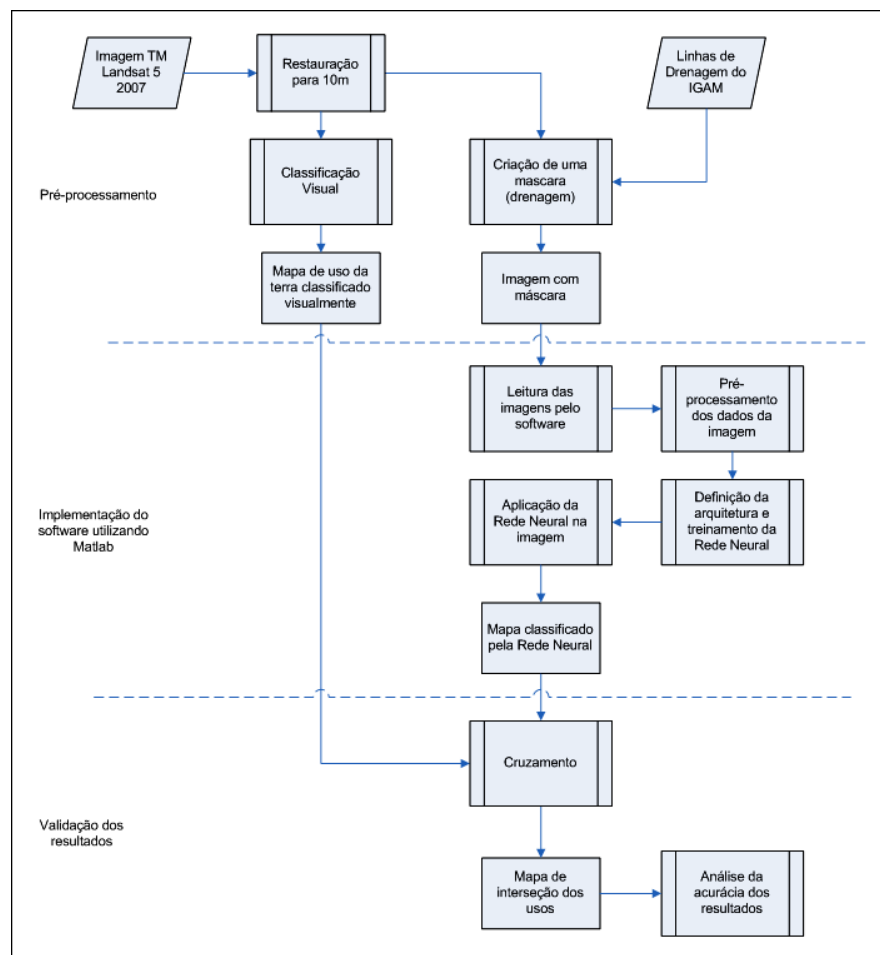


Figura 3.4 Diagrama de blocos da metodologia (Adaptado de ANDRADE, 2011).

### 3.2.1 Pré-processamento da imagem

O reconhecimento de padrões em uma imagem depende muito da qualidade da própria imagem, portanto, para que não ocorram erros no reconhecimento é necessário que a imagem passe por um tratamento anterior, que visa melhorar as características destas, ou destacar os pontos de interesse, possibilitando aos sistemas melhores taxas de acerto.

Para a realização da classificação, os dados de sensoriamento remoto foram submetidos aos pré-processamentos necessários para que a RNA fosse capaz de reconhecer as classes. A metodologia utilizada foi fundamentada no trabalho de ANDRADE (2011). A Figura 3.5 ilustra este processo.

A metodologia proposta incluiu máscaras na rede de drenagem e na área urbana, diminuindo assim a quantidade e a variabilidade dos alvos observados nas imagens. Para o desenvolvimento desta máscara, foi utilizada a Linguagem Espacial para Geoprocessamento Algébrico (LEGAL), do SPRING.

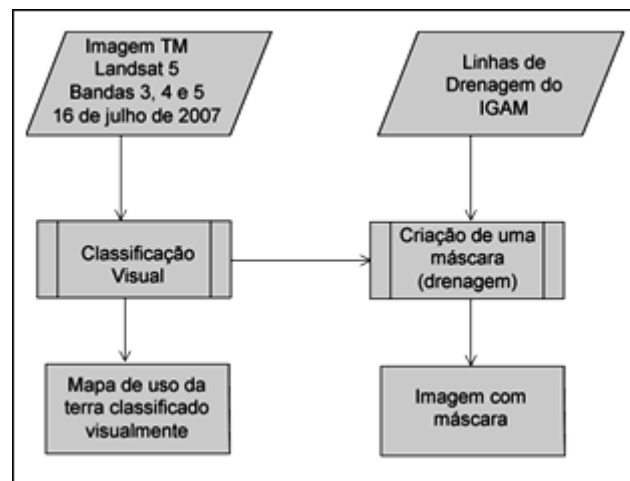


Figura 3.5 Pré-processamento da imagem (ANDRADE, 2011).

Foram utilizadas as linhas de drenagem do Instituto Mineiro de Gestão das Águas (IGAM), e sobre elas realizado o levantamento espacial



das áreas que deveriam estar preservadas utilizando a relação de proximidade (*buffer*) criando-se uma máscara ao longo da rede de drenagem, em cada uma das três bandas, seguindo a resolução 303/2002 do Código Florestal do CONAMA (Conselho Nacional do Meio Ambiente). Em seguida, foi realizado o cruzamento do *buffer* com o mapa de uso da terra utilizando a Linguagem LEGAL do SPRING, e atribuído o valor 10 aos pixels que se encontravam nestas áreas, o valor 10 foi escolhido para que a rede não confundisse o pixel com o valor de alguma classe. Foi criada também, uma máscara na área urbana de Três Pontas e atribuído aos pixels o valor de 255 (ANDRADE, 2011).

### **3.2.2 Procedimento metodológico para desenvolvimento do software**

A metodologia empregada para a implementação do programa utilizando o MATLAB pode ser observada pelo diagrama de blocos da Figura 3.6.

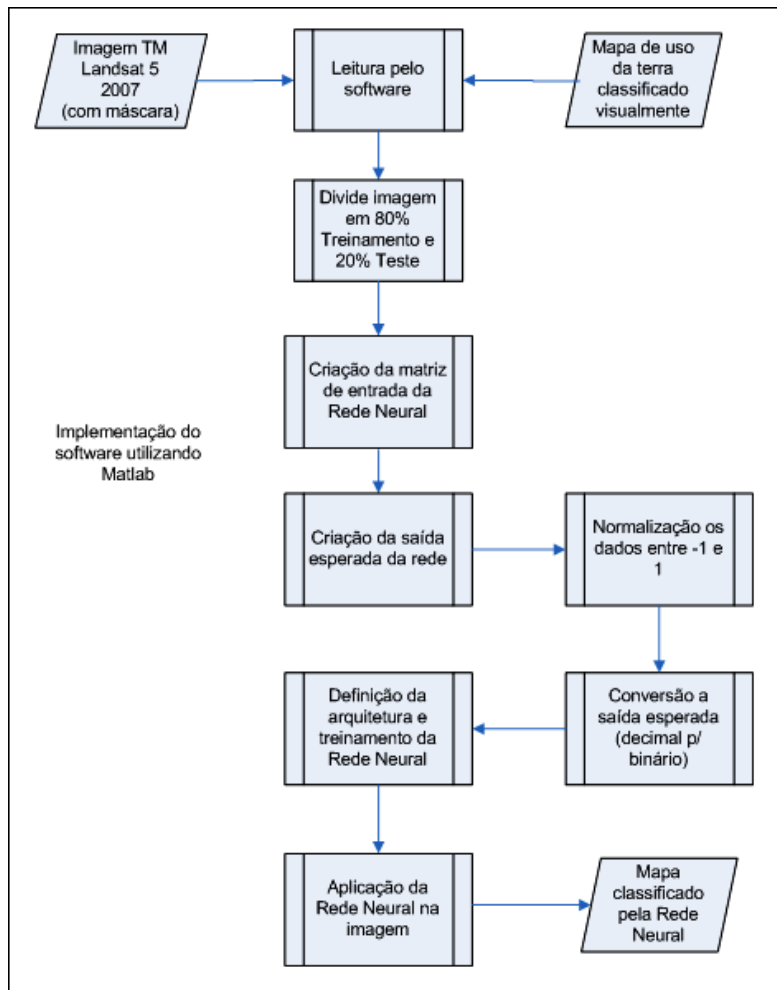


Figura 3.6 Diagrama de blocos da metodologia da implementação.

### Leitura das imagens pelo software

O primeiro passo na implementação do software foi a leitura das bandas da imagem. Cada cena do satélite TM/Landsat-5 possui 7 bandas, sendo as bandas 3, 4 e 5 as utilizadas neste trabalho. As 3 bandas foram salvas em uma variável representada no software MATLAB por uma matriz ( $n \times m$ ) onde cada pixel é um elemento dessa matriz, com valores variando de 0 e 255 tons de cinza. Na Figura 3.7 temos o exemplo de uma das bandas da imagem (banda 3), representada por uma matriz no MATLAB.

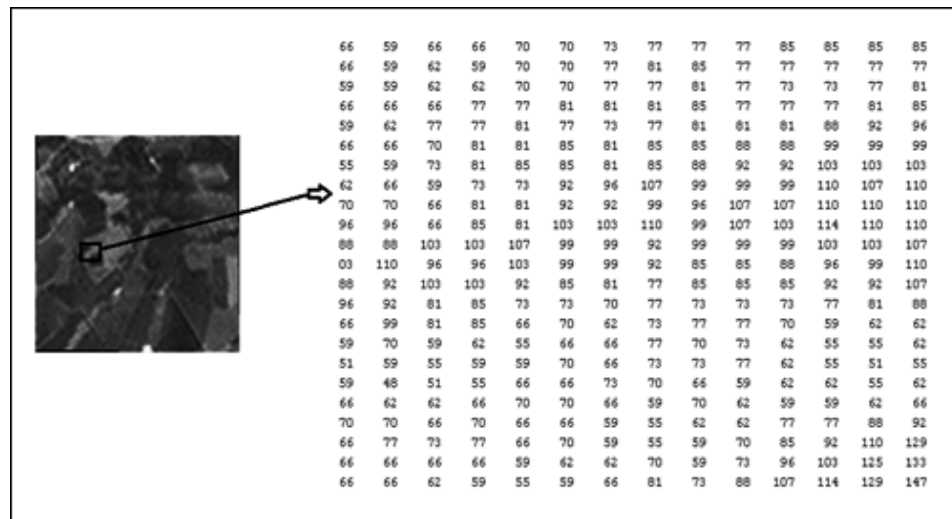


Figura 3.7 Exemplo da banda 3 da imagem.

Além das bandas da imagem, foi salva também a imagem de Uso da Terra classificada manualmente. A imagem possui 5 classes representadas na Tabela 3.1.

Tabela 3.1 Classes da imagem de Uso da Terra.

Valor pixel	Cor	Classe
1	Vermelho	Café
3	Verde	Mata
5	Azul	Água
6	Cinza	Área Urbana
7	Branco	Outros Usos

Na Figura 3.8 temos o exemplo de uma imagem de Uso da Terra representada por uma matriz no MATLAB.




Figura 3.8 Exemplo de uma imagem de Uso da Terra.

### Divisão da imagem em Treinamento e Teste

Durante a execução do software é necessário que uma parte da imagem seja destinada ao treinamento da rede e o restante da imagem para o teste. A forma de divisão utilizada neste trabalho foi deixar 80% da imagem para o treinamento da rede e os 20% restantes para o teste (Figura 3.9).

A porcentagem da imagem dedicada ao treinamento deve conter amostras representativas de todas as classes presentes na imagem para que a rede identifique todas as classes durante o teste da rede.




Figura 3.9 Divisão da imagem em treinamento e teste.

Após a imagem ser dividida em treinamento e teste foi gerada uma matriz no formato desejado da entrada da rede e também a saída desejada para que seja feito o treinamento da rede.

### **Criando a matriz de entrada da rede**

Para criar a matriz de entrada da rede é necessário percorrer a matriz de cada banda da imagem com uma janela quadrada, com tamanho a ser definido, como por exemplo, 3x3, 4x4, 5x5, como mostra a Figura 3.10.



Figura 3.10 Janela 3x3 que percorre as matrizes das bandas da imagem.

A cada passo desta janela a matriz quadrada é salva e transformada em um vetor coluna (Figura 3.11).




Figura 3.11 Janela 3x3 transformada em vetor.

Após a imagem ser totalmente percorrida, teremos uma matriz formada por todos os vetores criados enquanto a janela percorria a imagem (Figura 3.12). Essa matriz será a entrada de dados para treinamento da rede neural.

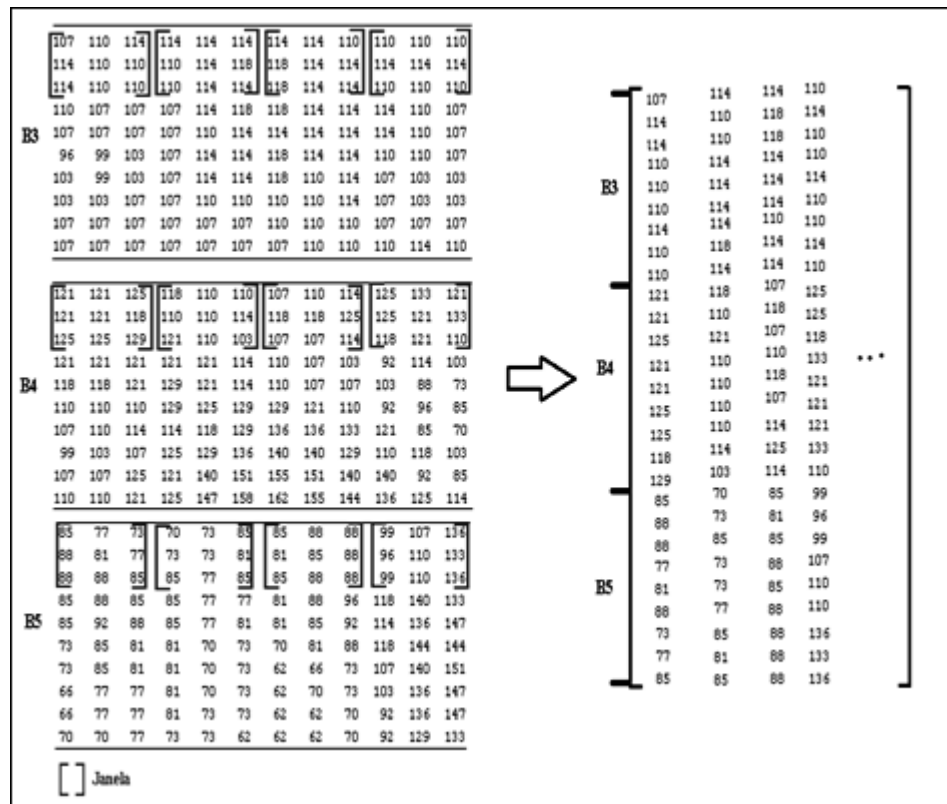


Figura 3.12 Entrada no formato desejado pela rede.

Essa matriz, inicialmente, tinha o formato *unit8*, ou seja, uma matriz de inteiros de 8 bits sem sinal, foi transformada em uma matriz *Double* para se adaptar ao formato de entrada desejado pela rede.

Por fim é feita a normalização dos dados, ficando estes entre -1 e 1, para que fosse possível a utilização da função de ativação de tangente hiperbólica ‘*tansig*’.

### Criando a saída esperada da rede

Para criar a saída desejada da rede a imagem de Uso da Terra classificada visualmente foi percorrida pela janela de varredura, de mesmo tamanho que a janela que percorremos as bandas da imagem TM/Landsat-5.

A cada passo da janela o pixel central é salvo e é formado um vetor linha com os pixels centrais a cada passo da janela, que será a saída desejada da rede (Figura 3.13). Esse vetor está no formato decimal e devera ser transformado em uma matriz binária de 5 linhas por m colunas, já que encontramos 5 classes tendo então 5 saídas na rede. A normalização dos dados da saída da rede também é realizada.

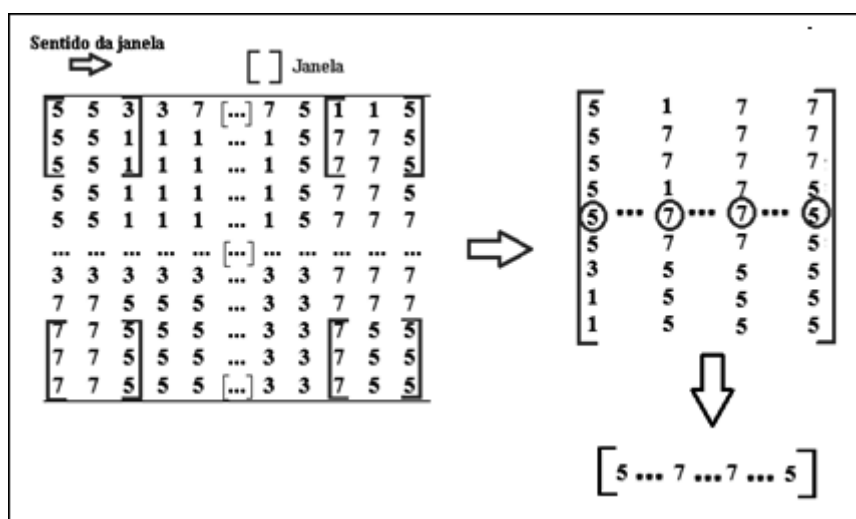


Figura 3.13 Saída desejada da rede.

### Definição da arquitetura da RNA

VIEIRA (2000) reporta que o algoritmo de aprendizado da rede neural mais utilizado na classificação de imagem oriundas do sensoriamento remoto é o retropropagação (backpropagation), com arquitetura multicamadas (MLP).

A definição do número de neurônios uma rede neural multicamadas implica na determinação prévia da dimensionalidade dos dados de entrada e das classes. Para determinar o número de camadas de entrada, camadas escondidas e o número de neurônios de cada camada foram executados testes que ajudaram na escolha da arquitetura para a melhor classificação desta



imagem. Esses testes tiveram sua corretude testada através da análise do índice estatístico Kappa, para cada arquitetura testada.

O primeiro passo foi definir o tamanho ideal da janela de varredura da imagem para a criação da entrada e saída esperada da rede e posteriormente o teste da rede. Para tanto analisamos os resultados da validação cruzada coletando os melhores resultados encontrados e o tamanho da janela em que estes foram encontrados. O tamanho das janelas varia de 3x3 a 25x25.

Quando se trata de definir o número de camadas da rede e o número de neurônios de cada camada devemos levar em conta que a rede criada pelo software identifica a quantidade de neurônios da camada de entrada, que é o número de amostras que foi passado, e a quantidade de neurônios da camada de saída, que é a quantidade de classes. Portanto foram feitos testes com 1 e 2 camadas escondidas.

A função de treinamento utilizada foi a *'trainrp'*, que é uma função de treinamento da rede disponibilizada pelo software MATLAB, onde os valores de pesos e bias são atualizados de acordo com algoritmo *resiliente backpropagation*.

A função de ativação dos neurônios foi a *'tansig'*, função tangente hiperbólica sigmoide que calcula o valor de saída de um neurônio.

### **Treinamento e teste da RNA**

Para o treinamento da RNA foi utilizada uma parcela da imagem, de acordo com a divisão citada anteriormente, onde todas as classes estavam representadas.

Foi utilizada a função *'train'* do Toolbox de Redes Neurais do MATLAB, onde são passados os seguintes parâmetros: rede, matriz de entrada da rede e a saída desejada em binário. Após o treinamento utiliza-se a função *'sim'* para o teste da rede.

### **Validação da classificação pela RNA**

Ao final de todo o processo de treinamento, todas as redes foram submetidas à validação, com um conjunto de amostras de teste independente do conjunto de amostras de treinamento. Após esse processo, a rede neural que obteve o melhor desempenho foi escolhida para ser utilizada na classificação do uso e cobertura da terra da área para cada composição da área avaliada.

A avaliação é a determinação do nível de exatidão ou confiança da classificação (índice Kappa) e da exatidão global da classificação de cada rede, através da análise da matriz de confusão (CONGALTON, 1991). Uma matriz de significância Kappa também será gerada para verificar a existência de diferenças significativas ou não entre os resultados obtidos e para a escolha da melhor arquitetura de rede para a classificação final das imagens (VIEIRA, 2000).

Para validar a classificação da rede neural foram realizados cruzamentos entre os mapas obtidos pela classificação da RNA com o mapa de referência (Figura 3.14).

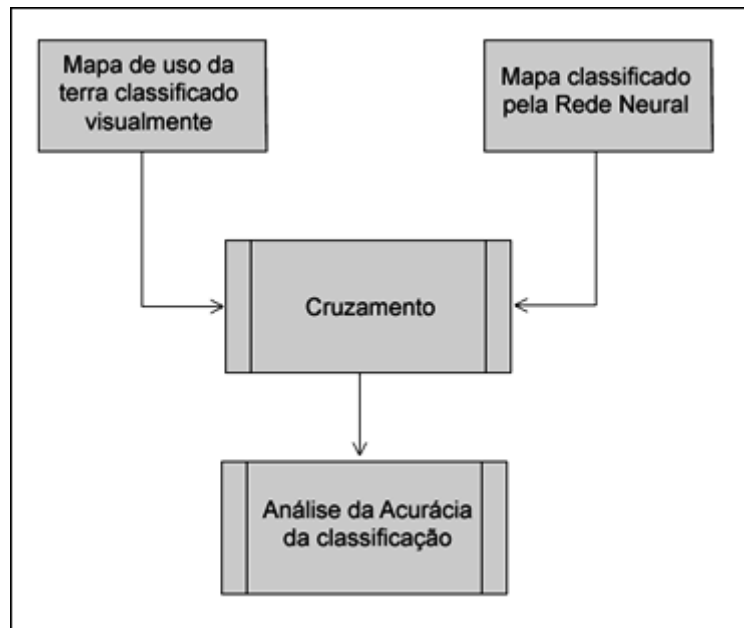


Figura 3.14 Validação da classificação

Para avaliar o desempenho da rede é necessária uma área de verificação (verdade de campo), onde todos os elementos da cena estão corretamente identificados, por tanto foram utilizados Mapas de Uso e Ocupação da Terra de Três Pontas – MG (EPAMIG, 2012), classificados visualmente e conferidos em campo (Figura 3.3).

Compara-se este Mapa de Uso com o mapa classificado pela Rede Neural Artificial. Para a comparação dos resultados são utilizadas matrizes de confusão onde estão exibidos os coeficientes que expressam a exatidão das classes, tanto do ponto de vista do usuário como a exatidão do ponto de vista do produto, possuindo também índices de acurácia global, adotado para este estudo o índice “Kappa”, que será visto no próximo capítulo.

## **4 RESULTADOS**

Neste capítulo são apresentados e discutidos os resultados obtidos com o desenvolvimento deste trabalho.

### **4.1 Definição da arquitetura da RNA**

Foram realizados testes para a definição da melhor arquitetura da rede para a classificação automática da imagem de satélite TM/Landsat-5 da região de Três Pontas, MG. Vários parâmetros foram modificados e testados até que fosse encontrada a melhor configuração da rede. Para este trabalho, foi empregado o método de rede neural multicamada (MLP) com o aprendizado de retropropagação (backpropagation).

Foram realizadas as seguintes alterações na arquitetura da RNA durante os testes: número de camadas; número de neurônios em cada camada; tamanho da janela de varredura da imagem e número de épocas de treinamento.

#### **4.1.1 Camadas escondidas e número de neurônios**

Um passo importante na construção da RNA é a definição da quantidade de camadas escondidas e a quantidade de neurônios em cada uma dessas camadas, já que o número de neurônios da camada de entrada e da camada de saída a própria rede define de acordo com o conjunto de dados de entrada e saída.

Foram realizados testes com até 2 camadas escondidas, com um número variável de neurônios em cada camada.

#### **4.1.2 Quantidade de épocas de treinamento**

Para determinar o número de épocas de treinamento foi preciso encontrar um equilíbrio entre a porcentagem de acerto do treinamento e a porcentagem de acerto do teste, pois após um determinado número de épocas de treinamento ocorre o *overfitting*, que é quando a rede decora os resultados, podendo levar a uma perda de generalização, atrapalhando assim o teste final. Por isso é necessário encontrar uma quantidade de épocas onde a porcentagem de acerto do treinamento não seja tão alta para que a rede não decore os resultados e assim a porcentagem de acerto do teste da rede seja a melhor possível. A quantidade mínima e máxima de épocas foi, respectivamente, 250 e 2500.

#### **4.2 Tamanho da janela de varredura da imagem**

O tamanho da janela de varredura é uma das principais variáveis utilizadas pelo software e ela define qual o tamanho da janela que percorre as matrizes das bandas das imagens e conseqüentemente define o tamanho do vetor de entrada da rede neural.

Para definir o tamanho ideal da janela de varredura foi criada uma rede com 2 camadas escondidas com 87 e 55 neurônios na primeira e na segunda camada, respectivamente, com 2000 épocas de treinamento. Os dados utilizados para o treinamento foram os mesmos utilizados durante o teste da rede. Geramos a imagem de saída da rede e a comparamos com a imagem de referência classificada visualmente (Figura 4.1).

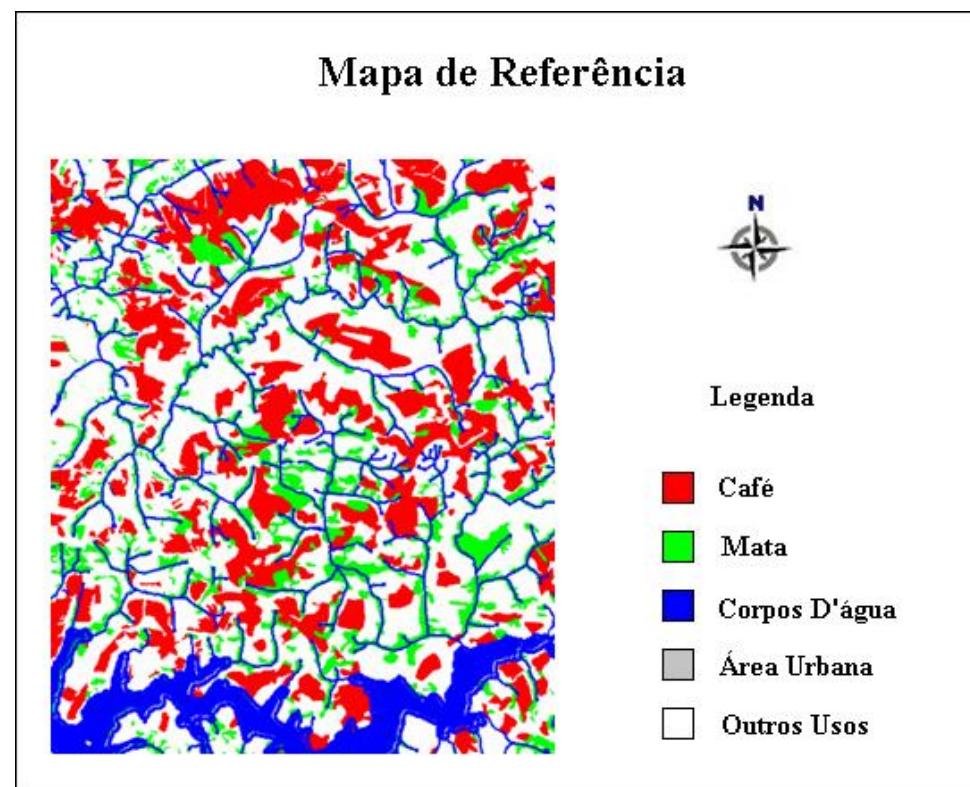


Figura 4.1 – Mapa de referência.

O objetivo do teste foi encontrar as janelas de varredura que obtiveram o melhor desempenho e que não atrapalharam na construção do mapa classificado pela rede neural, os resultados dos testes podem ser vistos na Tabela 4.1.

Tabela 4.1 Configurações utilizadas para realização dos testes da janela de varredura.

Configuração	Janela de Varredura da imagem	Camadas escondidas	Neurônios		Épocas de Treinamento	Índice Kappa
			1ª Camada	2ª Camada		
1	25x25	2	87	55	2000	0.5122
2	23x23	2	87	55	2000	0.5251
3	21x21	2	87	55	2000	0.5454
4	19x19	2	87	55	2000	0.5840
5	17x17	2	87	55	2000	0.6038
6	15x15	2	87	55	2000	0.6319
7	13x13	2	87	55	2000	0.6637
8	11x11	2	87	55	2000	0.6855
9	9x9	2	87	55	2000	0.6892
10	7x7	2	87	55	2000	0.6687
11	5x5	2	87	55	2000	0.6542
12	3x3	2	87	55	2000	0,6490

Podemos notar que o tamanho de janela 11x11 apresenta um dos melhores Kappa na fase de treinamento, porém a distorção da imagem construída pela rede prejudica sua utilização (Figura4.1).




Figura 4.2 – Mapa classificado pela RNA, tamanho de janela = 11x11.



Podemos notar também que o Kappa é maior nos tamanhos de janela 5x5, 7x7 e 9x9, onde também não há distorção da imagem, como visto nas Figuras 4.1, 4.2 e 4.3, respectivamente.

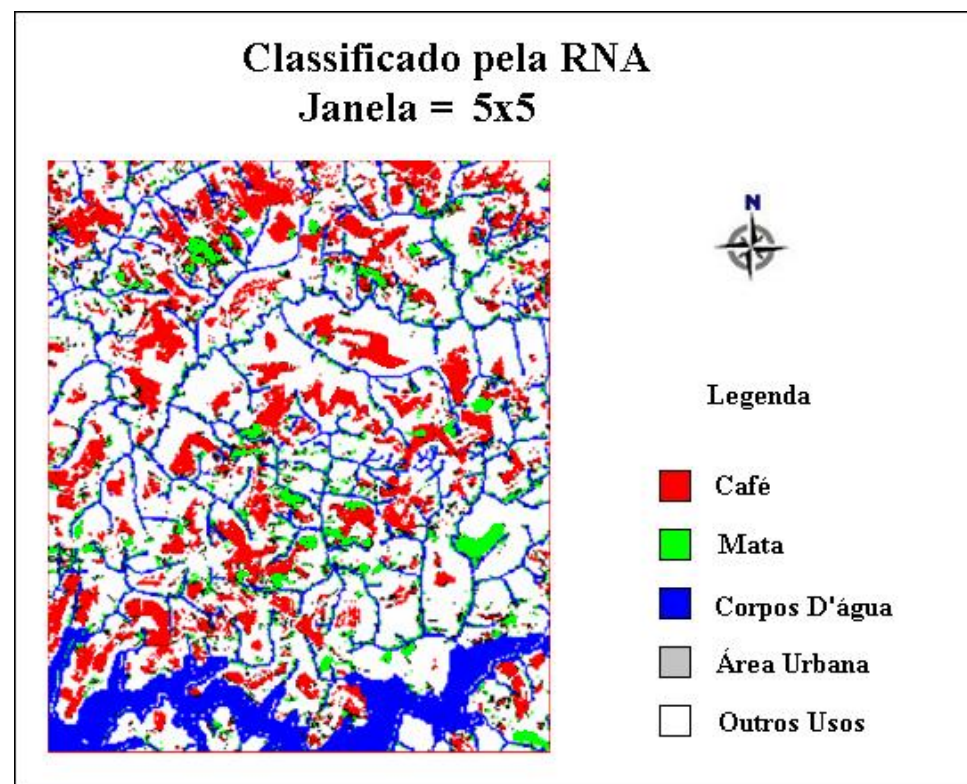


Figura 4.3 – Mapa classificado pela RNA, tamanho de janela = 5x5.

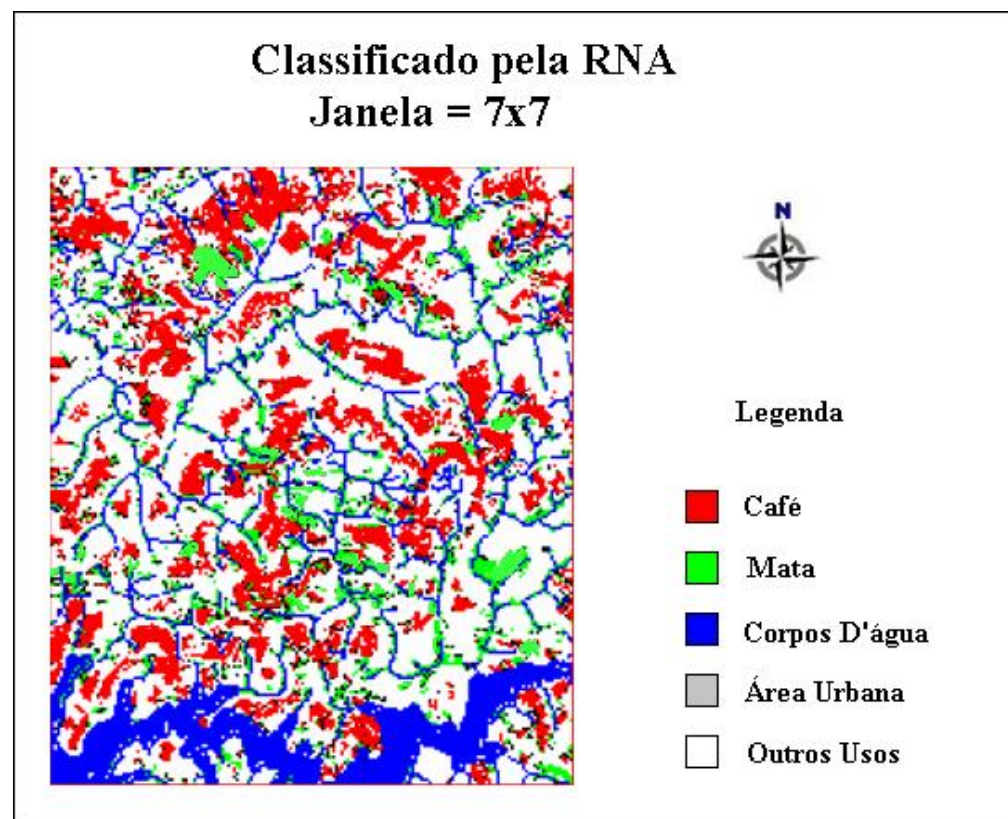


Figura 4.4 – Mapa classificado pela RNA, tamanho de janela = 7x7.




Figura 4.5 – Mapa classificado pela RNA, tamanho de janela = 9x9.

No tamanho da janela de varredura 3x3 o Kappa não é tão alto, porém nos testes realizados nas etapas seguintes deste trabalho veremos que na construção da imagem ele se sai bem, não distorcendo a imagem e com um Kappa muito bom.

Nas janelas maiores (13x13 a 25x25) há uma distorção na imagem e quando é gerada a matriz de confusão o Kappa é baixo.

Portanto os melhores tamanhos de janela, de acordo com as dimensões da imagem de referencia, são 3x3, 5x5 e 7x7. Posteriormente, ao realizarmos os testes, veremos que tamanhos de janela 3x3 e 5x5 foram os que apresentaram os melhores resultados.

### **4.3 Resultados gerais**

Foram realizados diversos testes para definição da arquitetura que melhor classificasse a imagem. Segundo os resultados obtidos verificamos que os tamanhos de janela 3x3 e 5x5 foram os que apresentaram melhores resultados, com isso os testes realizados foram apenas com os tamanhos de janela citados. Os melhores resultados podem ser vistos na Tabela 4.2.

Tabela 4.2 Configurações utilizadas para realização dos testes.

Configuração	Janela de Varredura da imagem	Camadas escondidas	Neurônios		Épocas de Treinamento	Índice Kappa
			1ª Camada	2ª Camada		
1	3x3	1	18	-	2500	0,6599
2	3x3	1	52	-	2000	0,6643
3	3x3	2	121	60	2500	0,6702
4	3x3	2	87	55	1000	0,6685
5	3x3	2	50	25	1500	0,6675
6	5x5	1	18	-	1500	0,6595
7	5x5	1	52	-	1000	0,6628
8	5x5	2	121	60	250	0,6711
9	5x5	2	87	55	500	0,6686
10	5x5	2	50	25	1000	0,6677

Podemos notar que quando utilizamos apenas uma camada escondida o desempenho da rede não é satisfatório, e quando aumentamos o numero de camadas escondidas o desempenho da rede melhora gradativamente. Podemos notar também que a medida que diminuimos o numero de neurônio em cada camada o desempenho da rede piora.

Os resultados em destaque, em vermelho, foram os melhores encontrados para os tamanhos de janelas 3x3 e 5x5, com índices Kappa 0,6702 e 0,6711 respectivamente.

A arquitetura que apresentou melhor resultado foi uma rede neural com 2 camadas escondidas com 121 e 60 neurônios na primeira e segunda camada, respectivamente, com uma taxa de aprendizado de 0,01; fator de momentum de 0,5. Como critério de parada do treinamento da RNA foi estabelecido o limite de 1.000 épocas. Através do gráfico do erro médio quadrático pode-se observar que a medida que aumenta o numero de épocas de treinamento o erro vai diminuindo até chegar um ponto em que ele fica estável (Figura 4.6).




Figura 4.6 Gráfico erro médio quadrático.

Nos testes realizados, observou-se que, aumentando o número de camadas e o número de neurônios, a rede não produzia resultados melhores que os já encontrados.

A cena classificada resultante da aplicação da arquitetura anterior da rede neural treinada é apresentada na Figura 4.1.

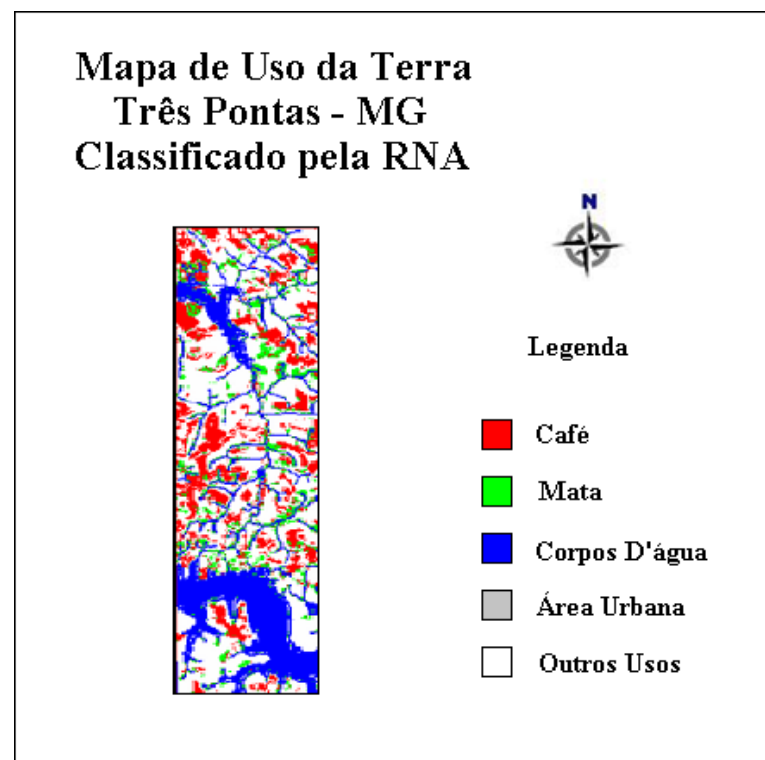


Figura 4.7 – Mapa da região de Três Pontas - MG, classificado pela RNA.



Em relação ao mapa de referência, o índice de acurácia Kappa do mapa classificado pela RNA ficou em 0,6711 com um índice global de 79.6025%.

Segundo Galparsoro e Fernández (2001) este é considerado um índice bom. O índice Kappa obtido na classificação por RNA pode ter sido prejudicado pelos fatores ambientais que interferem no padrão espectral da imagem, tais como variações do estágio fenológico, vigor vegetativo, espaçamento das plantas nas lavouras e tratos culturais utilizados, existência de culturas intercalares, relevo acidentado causando sombra e baixa resolução espacial das imagens Landsat utilizada. Contudo, se comparados aos resultados obtidos por ANDRADE (2011), a RNA apresentou melhor resultado na classificação, já que ANDRADE(2011) obteve um índice global de 67,61% e um acerto na classificação de áreas cafeeiras de 51,99%.

VIEIRA et al. (2009) concluíram que o reconhecimento de padrões da cultura cafeeira por métodos automatizados é dificultado também pela similaridade do padrão espectral café/mata. Apesar do baixo índice de acurácia Kappa obtido na classificação, a classe de café obteve um acerto de 76,25% na classificação.

A matriz de confusão entre o mapa de referência e o classificado pela RNA é apresentada na Tabela 4.3, contendo também os erros de omissão e comissão para cada classe e a exatidão do produtor e do consumidor. A matriz contém as taxas de erro e acerto da classificação para cada classe em porcentagem de área.

Tabela 4.3 Matriz de confusão da classificação da região de Três Pontas - MG.

<b>Mapa Classificado pela RNA</b>						
<b>Mapa Classificado Visualmente</b>	<b>Café em Produção</b>	<b>Mata</b>	<b>Água</b>	<b>Outros Usos</b>	<b>Erro de omissão</b>	<b>Exatidão do produtor</b>
<b>Café em Produção</b>	<b>76,25</b>	16,63	0,36	13,33	23,96	76,04
<b>Mata</b>	5,27	<b>54,40</b>	4,69	4,16	45,60	54,40
<b>Água</b>	0,58	7,25	<b>89,37</b>	2,84	10,63	89,37
<b>Outros Usos</b>	17,91	21,72	5,58	<b>79,66</b>	20,34	79,66
<b>TOTAL</b>	<b>100,0</b>	<b>100,0</b>	<b>100,0</b>	<b>100,0</b>		
<b>Erro de comissão</b>	53,73	49,09	10,01	9,40		
<b>Exatidão do consumidor</b>	46,27	50,91	89,99	90,60		
<b>Índice de exatidão global</b>	79,6025		<b>Kappa</b>		0,6711	

Analisando a matriz de confusão, pode-se observar que a RNA teve um bom desempenho na classificação de áreas cafeeiras, apresentando maior confusão na classificação com áreas de outros usos. O total das áreas de café classificadas corretamente corresponde a 76,25% da área. A RNA confundiu áreas cafeeiras com áreas de outros usos, classificando incorretamente 17,91% de áreas de outros usos como café.

A classe “outros usos” obteve uma boa classificação, com uma porcentagem de acerto de 79,66%. Aproximadamente 13,33% de áreas cafeeiras e 4,16% de áreas de mata, foram classificadas incorretamente como outros usos.

Uma dificuldade de classificação apresentada pela RNA pode ser observada na classe mata, que obteve como acerto 54,40%. A classificação da mata teve grande confusão com áreas de café, devido ao padrão espectral muito próximo (VIEIRA, 2006), classificando erroneamente 16,63% de áreas de café como mata. A criação de máscaras na rede de drenagem auxiliou na classificação eliminando o erro de classificação entre as classes temáticas mata e café ao longo dos drenos.

Outra dificuldade não esperada foi na classificação da classe água, que obteve uma taxa de acerto de 89,37% ,era esperado que essa taxa fosse maior devido a criação da máscara. O resultado não foi melhor devido a confusão da rede com as áreas de sombra e devido ao fato da rede considerar uma janela de pixel e não pixel por pixel.

Analisando os erros de comissão e omissão, pode-se observar que aproximadamente 53,73% da área, em km<sup>2</sup>, mapeada como café não correspondia espacialmente ao real, o que equivale aos erros de comissão para essa classe.

Podemos verificar através da exatidão do produtor que o café obteve 76,04% de acerto na classificação. A classe que obteve pior resultado foi a mata com 54,40%.

## 5 CONCLUSÃO

### 5.1 Conclusão final

Neste trabalho, foi demonstrado o potencial das redes neurais na classificação automática de áreas cafeeiras em imagens de satélite, o que justifica futuros trabalhos nesta área.

A ferramenta MATLAB mostrou-se muito eficiente na implementação do software.

Ao longo do desenvolvimento deste trabalho foram realizados vários testes visando chegar à melhor configuração de rede neural para o problema de identificação de áreas cafeeiras em imagens de satélite, especificamente na imagem Landsat/TM da cidade de Três Pontas, sul de Minas Gerais.

Conclui-se que o tamanho da janela de varredura influencia na classificação bem como na montagem de imagem depois de classificada pela rede.

Em relação ao número de camadas escondidas da rede, observou-se que não é necessária a utilização de mais que duas camadas escondidas, pois os resultados com mais de duas não são significantes.

Neste trabalho foram incluídas máscaras na rede de drenagem e na área urbana, diminuindo assim a quantidade e a variabilidade dos alvos observados nas imagens. O índice de acurácia Kappa obtido na região cafeeira de Três Pontas foi de 0,6711, que é um índice considerado bom, o acerto das áreas de café foi de 76,25% da área. Apesar de ainda não ter sido incorporado à RNA, nenhum outro parâmetro, a não ser o espectral, a metodologia proposta possibilitou discriminar todas as classes de saída pré-estabelecidas. O erro na classificação realizada pela rede neural é influenciado pela ambiguidade de áreas

de café com áreas de mata, tendo em vista os padrões espectrais muito próximos destas duas classes de uso e cobertura do solo.

Na região de Três Pontas, tanto o resultado obtido neste trabalho quanto o obtido por ANDRADE (2011), foram obtidos com a classificação realizada com redes neurais, tendo ANDRADE (2011) um acerto nas áreas cafeeiras de 51,99%.

Percebe-se que a criação da máscara de drenagem ajudou a rede a melhor identificar as classes propostas, uma vez que a máscara eliminava as áreas de vegetação natural, diminuindo assim a confusão espectral entre as classes café e mata.

Por fim, pode-se considerar que as Redes Neurais Artificiais podem ser consideradas como uma ferramenta promissora para análise de áreas cafeeiras em imagens de satélite.

## **5.2 Trabalhos futuros**

Trabalhos Futuros visam a utilização de outros tipos de imagens, advindas de outros satélites e outras regiões, além do acréscimo de outras características como forma, textura, índice de vegetação (NDVI).

Poderiam também ser feitos testes em imagens com resoluções espaciais e temporais melhores. Além de testar a metodologia em outras áreas cafeeiras de Minas Gerais.

## REFERÊNCIAS

ANDRADE, L. N.; VIEIRA, T. G. C.; ALVES, H. M. R.; VOLPATO, M. M. L. & SOUZA, V. C. O. **Aplicação de Redes Neurais Artificiais (RNA) na análise e classificação de áreas cafeeiras da região de Machado-MG.** In: XXXIX Congresso Brasileiro de Engenharia Agrícola (CLIA/CONBEA), Vitória, 2010.

ANDRADE, L. N. **Redes neurais artificiais aplicadas na identificação automática de áreas cafeeiras em imagens de satélite.** Tese (Mestrado em Ciência da computação) - Universidade Federal de Minas Gerais, Belo Horizonte, 2011.

BENEDIKTSSON, J. A., SWAIN, P. H., ERSOY, O. K. **Neural Network Approaches Versus Statistical Methods in Classification of Multisource Remote Sensing Data.** IEEE Transactions on Geoscience and Remote Sensing, v. 28, n. 4, 1990.

BOCANEGRA, C.W.R.. **Procedimentos para tornar mais Efetivo o Uso das Redes Neurais Artificiais em Planejamento de Transportes.** Dissertação (Mestrado) - EESC/USP, São Carlos, 2002.

BRAGA, A. P.; CARVALHO, A. C. P. L. F.; LUDERMIR, T. B. **Redes neurais artificiais: teoria e aplicações.** 2 Ed. Rio de Janeiro: LTC, 2007. 226p.

BRONSVELD, K.; CHUTIRATTANAPAN, S.; PATTANAKANOK, B.; SUWANWEAKAMTORN, R.; TRAKOOLDIT, P. **The use of local knowledge in land use/land cover mapping from satellite images.** ITC Journal. v. 4, 1994.

CÂMARA, G.; CASANOVA, M. A.; HEMERLY, A. S.; MAGALHÃES, G. C.; MEDEIROS, C. M. B. **Anatomia dos Sistemas de Informação Geográfica**. São José dos Campos: INPE, 1996. 193p.

CONAB. **Companhia Nacional de Abastecimento**. Disponível em: <<http://www.conab.gov.br>>. Acesso em: 10 abril. 2012.

CONGALTON, R. G. **A review of assessing the accuracy of classifications of remotely sensed data**. Remote Sensing of Environment, v.49, n.12, 1991.

COSTA, T.C.C. **Avaliação de estratégias para classificação de imagens orbitais em mapeamento de uso e cobertura da terra**. Dissertação (Doutorado em Ciência Florestal) - Universidade Federal de Viçosa, Viçosa. 1999. 109 p.

CRÓSTA, A.P. **Processamento digital de imagens de sensoriamento remoto**. Campinas: IG/UNICAMP, 1992. 170 p.

EPAMIG. Unidade Regional do Sul de Minas. Laboratório de Geoprocessamento. **Geosolos**. Lavras, 2012. Disponível em: <[www.epamig.br/geosolos/](http://www.epamig.br/geosolos/)>. Acesso em: 10 dez. 2012.

FERNÁNDEZ, CABALLERO et al. **On Motion Detection Through a Multi-Layer Neural Network Architecture**. Neural Networks, v.13, 2003.

GALO, M. L. B. T. **Caracterização Ambiental do Parque Estadual Morro do Diabo através de dados e técnicas de Sensoriamento Remoto: Abordagens utilizando redes neurais artificiais**. Tese (doutorado em ciências da engenharia

ambiental), Escola de Engenharia de São Carlos, Universidade de São Paulo, São Carlos, 2000. 205p.

HAYKIN, S. **Neural Networks: A Comprehensive Foundation**. USA: Macmillan Publishing. 1994. 696p.

HAYKIN, S. **Redes Neurais. princípios e prática**. Porto Alegre: Bookman, 2001. 900 p.

HEPNER, G. F. **Artificial Neural Networks Classification using a Minimal Training Set: Comparison to Conventional Supervised Classification**. Photogrammetric Engineering and Remote Sensing, v. 56, n. 4, 1990.

LIU, Z. K., XIAO, J. Y. **Classification of remotely-sensed image data using artificial neural networks**. International Journal of Remote Sensing, v. 12, n. 11, 1991.

INSTITUTO NACIONAL DE PESQUISAS ESPACIAIS (INPE). **Software SPRING**. São José dos Campos: INPE, 2000.

KINOSHITA, S.K.; MARQUES, P.M.A. e FRÈRE, A.F. **Utilização da Análise de Componentes Principais e Redes Neurais Artificiais para a Classificação de Nódulos em Mamogramas Digitalizados**. Anais do CBEB, 2000.

LIPPMANN, R. P.. **An introduction to computing with neural nets**. IEEE ASSP Magazine, v.4, 1987.



MATLAB. **User`s Guide – Neural Network Toolbox**, version 6.0. Mth Works. 2010.

MEDEIROS, L. F. **Redes neurais em Delphi**. Florianópolis: Visual Books Editora, 2003. 115p.

MEIRELES, E. J. L.; VOLPATO, M. M. L.; ALVES, H. M. R.; VIEIRA, T. G.C. **Zoneamento agroclimático: um estudo de caso para o café**. Informe Agropecuário, Belo Horizonte, v. 28, n. 241, 2007.

MOREIRA, M. A. **Fundamentos do sensoriamento remoto e metodologias de aplicação**. 2 ed. Viçosa: UFV. 307 p. 2003.

MOREIRA, M. A.; ADAMI, M.; RUDORFF, B. F. T. **Análise espectral e temporal da cultura do café em imagens Landsat**. Pesquisa Agropecuária Brasileira, volume 39, n.3,p. 231. 2004.

MURNION, S. D. **Comparison of Back Propagation and Binary Diamond Neural Networks in the Classification of a Landsat TM Image**. Computers & Geosciences, v.22, n.09, 1996.

NOVO, E. M. L. M. **Sensoriamento Remoto: Princípios e Aplicações**. São Paulo, Edgard Blücher. 1989.

PICOLI, M. C. A. **Estimativa da produtividade agrícola da cana-de-açúcar utilizando agregados de redes neurais artificiais: estudo de caso usina Catanduva**. Dissertação (Mestrado em Sensoriamento Remoto), Instituto Nacional de Pesquisas Espaciais, São José dos Campos: INPE, 2006. 90p.

RIBEIRO, S. R. A.; CENTENO J. A. S. **Clasificación del uso del suelo utilizando redes neurales y el algoritmo maxver**. Innovación, Año 14 n.1, Antofagasta – Chile, 2002.

RICHARDS, B. **Remote sensing and digital image analysis**. Springer –Verlag, Berlin. 1993.

SCHNEIDER, B.O. **Apostila de Computação Gráfica**. Universidade Federal de Lavras, Lavras – MG. 2001. 46 p.

SILVA, R. R. **Reconhecimento de imagens digitais utilizando redes neurais artificiais**. Monografia (Graduação em Ciência da Computação). Universidade Federal de Lavras, Lavras – MG. 2005. 51 p.

SILVA, A. L. G. & FRANCISCO, C. N. **Descrição dos Principais Sistemas Sensores Orbitais em Operação**. Disponível em: <[www.professores.uff.br/cristiane/Documentos/apostilasr.doc](http://www.professores.uff.br/cristiane/Documentos/apostilasr.doc)>. Acesso em: 10 dez. 2012.

SOUZA, F. P. C. **Localização e Leitura Automática de Caracteres Alfanuméricos: Uma Aplicação na Identificação de Veículos**. Porto Alegre. Dissertação (Mestrado em Engenharia Elétrica) – Universidade Federal do Rio Grande do Sul. 2000. 96 p.

SPRING. Site oficial do INPE – Instituto Nacional de Pesquisas Espaciais. **Tutorial de Geoprocessamento**. Disponível em: <[http://www.dpi.inpe.br/spring/portugues/tutorial/introducao\\_sen.html](http://www.dpi.inpe.br/spring/portugues/tutorial/introducao_sen.html)>. Acesso em: 15 dez. 2012.

TORINO, C. V. e BARRETO, D. T. **Detecção de Fumaça Através do Processamento de Imagem Utilizando Redes Neurais em um Sistema Híbrido**. XIV Congresso Brasileiro de Automática, Natal – RN, 2002.

VIEIRA, C. A. O. **Accuracy Of Remotely Sensing Classification Of Agricultural Crops: A Comparative Study**, Thesis Submitted to the University of Nottingham for the Degree of Doctor of Philosophy, 2000. 396 p.

VIEIRA, T. G. C.; ALVES, H. M. R.; LACERDA, M. P. C.; VEIGA, R. D.; EPIPHANIO, J. C. N. **Crop parameters and spectral response of coffee (Coffea arabica L.) areas within the state of Minas Gerais, Brazil**. Coffee Science, v.1, n.2, 2006.

VIEIRA, T. G. C.; ALVES, H. M. R.; VOLPATO, M. M. L.; SOUZA, V. C. O de.; BERNARDES, T. **Sistema de geoinformação para a cafeicultura do sul de Minas**. Informe Agropecuário, v.28, n.241, 2007.